



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Engenharia Elétrica e de Computação

ELLEN MARIANNE BERNAL CAVALHEIRO

OTIMIZAÇÃO DAS CONFIGURAÇÕES DE REDES DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA COM FONTES
DISTRIBUÍDAS

OPTIMIZATION OF ELECTRIC POWER DISTRIBUTION
NETWORK CONFIGURATIONS WITH DISTRIBUTED ENERGY
SOURCES

CAMPINAS

2017



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Engenharia Elétrica e de Computação

ELLEN MARIANNE BERNAL CAVALHEIRO

OTIMIZAÇÃO DAS CONFIGURAÇÕES DE REDES DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA COM FONTES
DISTRIBUÍDAS

Dissertação apresentada à Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Mestra em Engenharia Elétrica, na área de Automação.

ORIENTADOR: PROF. CHRISTIANO LYRA FILHO.

ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO DEFENDIDA PELA ALUNA ELLEN MARIANNE BERNAL CAVALHEIRO E ORIENTADA PELO PROF. DR. CHRISTIANO LYRA FILHO.

CAMPINAS
2017

Agência(s) de fomento e nº(s) de processo(s): CAPES, 1569620

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Luciana Pietrosanto Milla - CRB 8/8129

C314o Cavalheiro, Ellen Marianne Bernal, 1991-
Otimização das configurações de redes de distribuição de energia elétrica com fontes distribuídas / Ellen Marianne Bernal Cavalheiro. – Campinas, SP : [s.n.], 2017.

Orientador: Christiano Lyra Filho.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Sistemas de energia elétrica. 2. Distribuição de energia elétrica. 3. Geração distribuída de energia elétrica. 4. Otimização combinatória. 5. Algoritmos genéticos. I. Lyra Filho, Christiano, 1951-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Optimization of electric power distribution network configurations with distributed energy sources

Palavras-chave em inglês:

Electric power systems
Distribution of electricity
Distributed generation of electric energy
Combinatorial optimization
Genetic algorithms

Área de concentração: Automação

Titulação: Mestra em Engenharia Elétrica

Banca examinadora:

Christiano Lyra Filho [Orientador]
Marcius Fabius Henriques de Carvalho
Celso Cavellucci

Data de defesa: 27-07-2017

Programa de Pós-Graduação: Engenharia Elétrica

Comissão Julgadora – Dissertação de Mestrado

Candidato: Ellen Marianne Bernal Cavalleiro.

Data da Defesa: 27 de julho de 2017.

Título da Dissertação: Otimização das Configurações de Redes de Distribuição de Energia Elétrica com Fontes Distribuídas.

Prof. Dr. Christiano Lyra Filho (Presidente, FEEC /UNICAMP)

Prof. Dr. Marcius Fabius Henriques de Carvalho (PUC/CAMPINAS)

Prof. Dr. Celso Cavellucci (IC/UNICAMP)

A ata de defesa, com as respectivas assinaturas dos membros da Comissão Julgadora, encontra-se no processo de vida acadêmica do aluno.

AOS MEUS AMADOS PAIS E AMADA IRMÃ,
EULÁLIA, RAUF E EMILLE.

“Moça, olha só o que eu te escrevi
É preciso força pra sonhar e perceber
Que a estrada vai além do que se vê.”

Marcelo Camelo

AGRADECIMENTOS

Agradeço a Deus, por me dar forças, me guiar e me fortalecer em todos os momentos da minha vida; sem a ajuda Dele nada seria possível.

Aos meus amados pais Eulália e Rauf, pelo amor, ensinamentos e exemplo. A minha irmã Emille pelo amor, por compartilhar os meus sonhos e incentivá-los.

Aos meus queridos tios Marilene e Volmir, e minhas primas Milene e Aline que durante esses três anos sempre me acolheram e me fizeram sentir como se estivesse em casa.

Ao Freddy, que me ensinou a ir em busca dos meus sonhos.

A minha família, pela união.

Ao prof. Christiano, pela dedicação, paciência, orientação, pela confiança em mim e no desenvolvimento deste trabalho.

A todos os professores que contribuíram para minha formação.

Aos membros da banca examinadora, pelos comentários, sugestões e contribuições.

A Dani e a Sheila, pela confiança e amizade.

Ao André, que contribuiu para a realização desse trabalho, obrigada por se dispor a trabalhar conosco e a me ajudar nesta pesquisa.

Aos amigos do LABORE, Alan Caio, Petra, Marcos, André, Mateus, Rodrigo, André, Luciana e Bacalhau. Obrigada pela companhia, conselhos, momentos de alegria e também ajuda nos momentos de dificuldade.

A Clarice e Lari, pelo apoio e amizade.

Ao Luis, pelo apoio e suporte durante este período.

À FEEC/UNICAMP, pela ótima estrutura que oferece aos estudantes e pesquisadores. Agradeço também ao pessoal da secretaria, dos setores administrativos, da segurança e da limpeza, por serem sempre tão educados e atenciosos.

À CAPES, pelo apoio financeiro.

E a todos que, de alguma forma, contribuíram para o meu progresso como aluna e como pessoa.

RESUMO

Uma forma atraente de reduzir perdas em redes de distribuição de energia elétrica é através da abordagem do problema de reconfigurações de redes, o qual deve fornecer uma topologia para operação que minimize as perdas totais causadas pelas resistências elétricas nas linhas e equipamentos (perdas técnicas). A existência de geração distribuída e inovações adicionais associadas ao termo “*smart grids*” permitem aumentar os benefícios de encontrar melhores topologias de redes. Por outro lado, a presença de geração distribuída com injeções aleatórias requer uma nova perspectiva para modelagem do problema de reconfigurações das redes e o desenvolvimento de técnicas de solução apropriadas. Essas questões são o objeto deste trabalho. As principais características do problema de reconfiguração de redes com fontes distribuídas de valores aleatórios são inicialmente exploradas em uma rede maquete, desenvolvida para realçar as consequências da presença dessas fontes. A partir do estudo inicial com a rede maquete, o trabalho propõe um modelo para o problema de otimização da reconfiguração de redes que considera explicitamente injeções de energia com valores aleatórios. Um algoritmo genético construído com arquitetura de algoritmos genéticos baseados em chaves aleatórias direcionadas (BRKGA, acrônimo da descrição em inglês “*biased random-key genetic algorithm*”) é desenvolvido para resolver este problema difícil de otimização combinatória. Estudos de casos com redes de referência colocam em perspectiva a metodologia proposta. Os resultados mostram que as características aleatórias das fontes devem ser explicitamente modeladas nas abordagens dos problemas reconfigurações de redes. O trabalho fornece as bases para abordar este novo problema e aponta para caminhos de pesquisas adicionais na área.

Palavras-chave: Reconfiguração de Redes, Gerações distribuídas com injeções aleatórias, Redes de Distribuição de Energia Elétrica, *Smart Grids*, Algoritmos Genéticos Baseados em Chaves Aleatórias.

ABSTRACT

An attractive way to reduce losses in electric power distribution networks is addressing the network reconfiguration problem, which should give a topology for the primary distribution network that minimizes the total losses due to the electrical resistances in the lines and complementary equipment (technical losses). Distributed energy resources and additional innovations associated to “smart grids” allow enhancing the benefits of finding better network topologies. On the other hand, the integration of renewable energy sources with variable random outputs requires expanding the perspective in modeling the network reconfiguration problem and in the shaping of appropriate solution techniques. These issues are the object of this work. The main new features of the problem are explored with a maquette designed to highlight the consequences of random generation sources in the networks. Following, the work proposes a formulation for the problem that explicitly considers random energy sources. A state of the art genetic algorithm built under the biased random-key evolution framework (BRKGA) is developed to address this hard combinatorial optimization problem. Case studies with benchmark networks put into perspective the proposed methodology. Results show that random energy inputs should be explicitly modeled in contemporary approaches to the network reconfiguration problem. The work provides the grounds for addressing this new network reconfiguration problem and points to additional research paths in the area.

Keywords: Optimal Network Configurations, Distributed Energy Sources, Power Distribution Networks, Smart Grids, Biased Random-Key Genetic Algorithm.

LISTA DE FIGURAS

1.1	Exemplo de um sistema de energia elétrica.	20
1.2	Exemplo de um sistema de distribuição.	21
1.3	Gráfico característico de velocidade de ventos para geração eólica. Fonte: Oliveira (2014).	28
1.4	Rede de distribuição com componentes de <i>Smart Grid</i> . Fonte: imagem baseada em <i>IEEE PES Smart Grids</i> (2016).	29
2.1	Exemplo de configuração de operação e de reconfiguração por chaveamentos em uma rede de distribuição.	31
2.2	Rede Maquete – Caso Base	32
2.3	Configuração ótima para geração constante correspondente ao valor esperado das injeções.	33
2.4	Configuração ótima para os valores esperados de perdas.	34
2.5	Conjunto de arcos saindo do nó k	36
3.1	Árvore codificada.	40
3.2	Seleção pelo método da roleta de acordo com os dados apresentados na Tabela 3.2.	42
3.3	Transição da geração k para a geração $k + 1$ no BRKGA.	45
4.1	Fluxograma do BRKGA para o problema de reconfiguração de redes.	48
4.2	Decodificação de uma rede radial de um cromossomo.	50
4.3	Numeração em preordem de uma árvore representando uma rede radial.	50
4.4	<i>crossover</i> uniforme parametrizado.	51
4.5	Método de troca de ramos.	56
A.1	Rede 1	71
A.2	Rede 2	72
A.3	Rede 3	73

A.4	Rede 4	74
A.5	Rede 5	75
A.6	Rede 6	76

LISTA DE TABELAS

2.1	Demandas nos nós.	32
2.2	Probabilidades de valores de geração.	33
3.1	Cromossomos codificados por <i>Characteristic Vectors</i> e NRK.	40
3.2	Dados de indivíduos que participarão do método de seleção roleta.	41
3.3	Configurações de valores de parâmetros recomendados.	46
5.1	Dados das redes.	58
5.2	Parâmetros adotados no BRKGA.	58
5.3	Perdas e tempos de processamento.	59
5.4	Valores de ρ_a testados para as redes 1, 2, 3, 4, 5 e 6a.	60
5.5	Perdas e tempos de processamento para reinicialização com valores de 25, 50, 200 e 250.	60
5.6	Valores de injeções aleatórias.	61
5.7	Perdas e tempos de processamento.	61

LISTA DE ABREVIATURAS E SIGLAS

AG	<i>Algoritmo Genético</i>
BRKGA	<i>Biased Random-key Genetic Algorithm</i>
GRASP	<i>Greedy Randomized Adaptive Search Procedure</i>
MST	<i>Minimum Spanning Tree</i>
NA	Normalmente Aberta
NF	Normalmente Fechada
NRK	<i>Network Random Keys</i>
RKGA	<i>Random-key Genetic Algorithm</i>
SE	Subestação
SEE	Sistemas de Energia Elétrica
SDEE	Sistemas de Distribuição de Energia Elétrica

SUMÁRIO

1	Sistemas de Energia Elétrica	19
1.1	Introdução aos Sistemas de Energia Elétrica	19
1.2	Sistemas de Distribuição de Energia Elétrica	20
1.2.1	Perdas em Sistemas de Distribuição de Energia Elétrica	22
1.3	Reconfiguração de Redes para Redução de Perdas Técnicas em Redes Primárias de Distribuição Elétrica	22
1.4	Revisão Bibliográfica	23
1.4.1	O trabalho pioneiro de Merlin & Back	23
1.4.2	Década de 80	23
1.4.3	Década de 90	24
1.4.4	Após 2000	25
1.5	<i>Smart Grid</i>	27
2	Caracterização e Formulação do Problema	30
2.1	Representação por Grafos de Redes de Distribuição de Energia Elétrica . .	30
2.2	Limitante Superior para o Número de Configurações das Redes	31
2.3	Problema Maquete de Referência	32
2.4	Formulação Matemática do Problema	35
3	Algoritmos Genéticos Baseados em Chaves Aleatórias	38
3.1	Conceito Básicos	38
3.1.1	Representação do Cromossomo	39
3.1.2	Inicialização da População	40
3.1.3	Função de Avaliação	40
3.1.4	Seleção	41
3.1.5	Estratégia Elitista	42
3.1.6	Operadores Genéticos	43

3.2	Características do BRKGA	44
4	Solução do Problema por Algoritmo Genético Baseado em Chaves Aleatórias (BRKGA)	47
4.1	BRKGA para Redução de Perdas em Redes de Distribuição	47
4.2	Representação do Cromossomo	48
4.3	Função de Avaliação	49
4.4	<i>Crossover</i> e Evolução	51
4.5	Mutação	52
4.6	Algoritmo Genético Híbrido para a Solução do Problema de Reconfiguração de Redes	52
4.6.1	Características Gerais do Algoritmos Genético Híbrido	53
4.6.2	Formulação Matemática do Problema Para o Caso Determinístico .	53
4.6.3	Busca Local	54
5	Estudo de Casos	57
5.1	Características das Redes	57
5.2	Recursos Computacionais e Parâmetros do BRKGA	58
5.2.1	Recursos Computacionais	58
5.2.2	Parâmetros do BRKGA	58
5.3	Comparação do BRKGA com o AG Híbrido	58
5.4	Testes Adicionais	59
5.5	Avaliação do BRKGA para o Problema de Reconfiguração de Redes com Fontes Distribuídas de Valores Aleatórios	60
6	Conclusões e Perspectivas de Trabalhos Futuros	63
	Referências Bibliográficas	65
A	Topologia das Redes Estudadas	71

APRESENTAÇÃO DO TRABALHO

“E se eu for
O primeiro a prever
E poder desistir
Do que for dar errado?
Ahhh
Ora, se não sou eu
Quem mais vai decidir
O que é bom pra mim?
Dispensar a previsão
Ah, se o que eu sou
É também o que eu escolhi ser
Aceito a condição.”

Los Hermanos - *O Velho e o Moço* (2003).

A energia elétrica é transportada das fontes até os pontos de consumo através de linhas e equipamentos. Nessas linhas e equipamentos ocorrem dissipações de energia, devido às resistências elétricas, que causam perdas técnicas (por efeito joule). As perdas técnicas são mais expressivas nos sistemas de distribuição (Cavellucci 1998). Uma forma de reduzir as perdas técnicas, garantindo aos consumidores qualidade de fornecimento com o menor custo operacional possível é a utilização de instrumentos de trabalho na área de pesquisa operacional como: modelos matemáticos, técnicas de otimização, métodos estatísticos, computação numérica e métodos de inteligência computacional.

Existem várias alternativas para redução de perdas técnicas em redes de distribuição, como a gestão dos fluxos de energia reativa, melhorias físicas por substituição de cabos e equipamentos, otimização das redes, melhores configurações das redes e a adoção de fontes de gerações distribuídas. Neste trabalho, as reduções de perdas técnicas são obtidas através de melhores configurações para redes radiais de distribuição de energia elétrica com geradores distribuídos de injeções aleatórias, cenário para onde convergem as redes de distribuição, com as inovações em gerações e controles associadas ao conceito

de *Smart Grids*.

Encontrar configurações ótimas significa reconfigurar a rede de distribuição através da troca dos estados de chaves, normalmente abertas (NA) ou normalmente fechadas (NF), procurando encontrar configurações radiais de mínimas perdas (Queiroz & Lyra 2009). O número de possíveis configurações em uma rede de distribuição está associado ao número de árvores conexas que podem ser obtidas por abertura e fechamento de chaves existentes na rede.

Os engenheiros franceses Merlin & Back (1975) foram os primeiros a investigar o problema de encontrar as configurações ótimas de redes de distribuição de energia elétrica. O trabalho seminal de Merlin & Back impulsionou pesquisas e implementações na área. A partir dos anos 2000, os trabalhos na área começaram a considerar a inserção de gerações distribuídas. O conjunto de tecnologias que permitiram implementações de gerações distribuídas nas redes de distribuição veio a tornar-se conhecido pela expressão *Smart Grid*.

Os trabalhos que estudam o problema de encontrar configurações ótimas de redes radiais de distribuição com a presença de geração distribuída estão ainda numa fase exploratória, restrita a cenários de gerações determinísticas (*i.e.*, conhecidas a priori).

Este trabalho propõe um passo adicional na discussão sobre o problema de reconfiguração de redes radiais de distribuição, ao incluir a representação de aspectos aleatórios de gerações distribuídas. As características do problema são inicialmente exploradas em uma rede maquete de pequeno porte, projetada para realçar as consequências da presença de gerações aleatórias nas redes (Cavalheiro et al. 2016). A partir deste estudo inicial, desenvolve uma formulação matemática para o problema e estratégia de solução através dos algoritmos genéticos baseados em chaves aleatórias (BRKGA).

O trabalho está organizado em seis capítulos. O Capítulo 1 apresenta uma introdução aos sistemas de energia elétrica, com ênfase nos sistemas de distribuição. Apresenta também o problema de redução de perdas através de reconfigurações de redes e uma revisão bibliográfica.

O Capítulo 2 explora as características do problema em uma rede maquete de referência apresentada em Cavalheiro et al. (2016). Apresenta também uma formulação matemática para o novo cenário de encontrar configurações ótimas de redes radiais de distribuição com fontes distribuídas de valores de gerações aleatórios.

O Capítulo 3 apresenta uma introdução aos algoritmos genéticos baseados em chaves aleatórias (BRKGA) e detalha aspectos específicos do método de solução baseado nesses algoritmos.

O Capítulo 4 apresenta o algoritmo proposto para a solução do problema e descreve um algoritmo genético híbrido usado como referência de comparação, para avaliar a capacidade de busca do BRKGA.

O Capítulo 5 apresenta os estudos de casos.

Conclusões e perspectivas de trabalhos futuros são apresentados no Capítulo 6.

CAPÍTULO 1

SISTEMAS DE ENERGIA ELÉTRICA

“Yes, there are two paths you can go by
But in the long run
There’s still time to change the road you’re on
And it makes me wonder
Oh.”

Led Zeppelin - *Stairway To Heaven* (1971).

Este capítulo apresenta uma introdução aos sistemas de energia elétrica e destaca os sistemas de distribuição. O objetivo dos sistemas de distribuição de energia elétrica é entregar a energia aos pontos de consumo. As perdas técnicas de energia ocorrem ao longo de todo o sistema, sobretudo no sistema de distribuição. Uma alternativa para redução de perdas técnicas em redes de distribuição é encontrar configurações melhores para as redes, objeto deste estudo. O capítulo faz uma breve apresentação do problema e faz uma revisão bibliográfica sobre o tema.

1.1 Introdução aos Sistemas de Energia Elétrica

Os sistemas de energia elétrica (SEE) podem ser subdivididos em três grandes blocos: geração, transmissão e distribuição (Kagan et al. 2005). O sistema de geração é responsável pela transformação de energia potencial em energia elétrica. A geração é realizada nas centrais elétricas, utilizando normalmente máquinas elétricas rotativas, como os geradores síncronos - no Brasil, a geração elétrica é fortemente baseada em usinas hidroelétricas. O sistema de transmissão é responsável pelo transporte de energia dos centros geradores aos centros de consumo. Antes da energia chegar ao sistema de transmissão, ela passa por uma subestação, onde eleva-se a tensão da rede, de maneira a reduzir as perdas. As tensões são reduzidas em subestações abaixadoras quando a energia elétrica chega aos centros de consumo. O sistema de distribuição é formado por todas as

linhas e equipamentos desde a subestação abaixadora até cada um dos pontos de consumo; logo, é a parte do sistema responsável pela entrega da energia elétrica aos consumidores. A Figura 1.2 ilustra um sistema de energia elétrica (Queiroz 2005).

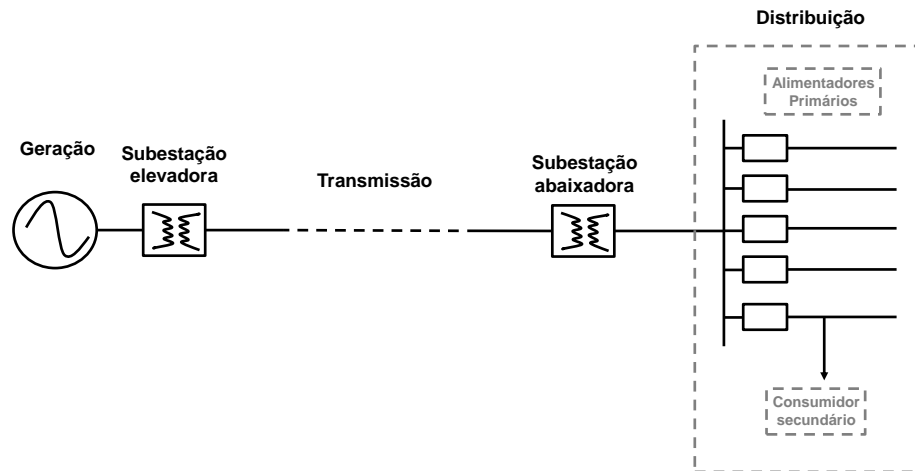


Figura 1.1: Exemplo de um sistema de energia elétrica.

1.2 Sistemas de Distribuição de Energia Elétrica

Os sistemas de distribuição de energia elétrica (SDEE) recebem energia do sistema de transmissão, ou sub-transmissão, através de linhas e equipamentos, e entrega a energia aos pontos de consumo. Normalmente os sistemas de distribuição são subdivididos em redes primárias e secundárias. As redes primárias são formadas pelos alimentadores e equipamentos que estão entre os barramentos das subestações de distribuição e o primário dos transformadores de distribuição. Redes secundárias são compostas por condutores de energia entre o secundário desses transformadores e os pontos de consumo (cargas). A Figura 1.2 ilustra um sistema de distribuição (Queiroz 2005). Os principais componentes dos sistemas de distribuição, para o contexto dos problemas estudados neste trabalho são descritos a seguir (Kagan et al. 2005).

- **Subestação:** As subestações de distribuição de energia elétrica (SEs), são responsáveis pela transformação da tensão de subtransmissão para a de distribuição primária. Normalmente estão localizadas perto dos pontos de consumo. As SEs possuem vários arranjos possíveis, variando com a potência instalada. A instalação de disjuntor e chaves possibilitam desconectar a SE da rede de transmissão ou desligar linhas que saem da subestação de distribuição, quando necessário.
- **Alimentador:** Os alimentadores são formados por condutores de energia (cabos ou linhas) que partem dos transformadores das SEs e alimentam os transformadores de

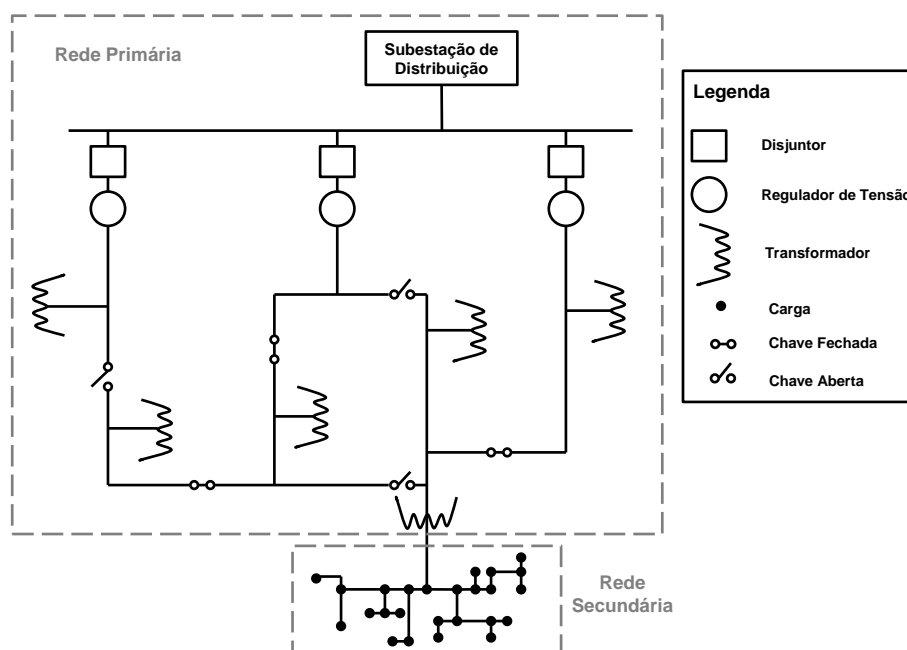


Figura 1.2: Exemplo de um sistema de distribuição.

distribuição.

- **Equipamentos de proteção:** Têm o objetivo de detectar condições anormais e iniciar uma ação corretiva para evitar danos ao sistema elétrico.
- **Disjuntor:** É um equipamento de proteção e tem o objetivo de proteger um circuito elétrico de danos causados por sobrecarga ou curto circuito. O objetivo do disjuntor é detectar uma condição de falha, interromper o circuito e isolar equipamentos.
- **Regulador de tensão:** É um dispositivo com a finalidade de realizar a manutenção da tensão de saída de um circuito elétrico, mantendo-a constante, independente da tensão de entrada.
- **Cabos:** São condutores de energia elétrica e podem ser construídos por materiais como o alumínio ou o cobre, e com um número variado de bitolas.
- **Carga:** É todo dispositivo que consome energia elétrica no sistema. As cargas são classificadas em indústrias, comerciais, residenciais e “outras”.
- **Chave seccionadora/fechada:** São chaves normalmente fechadas (NF), que são abertas quando ocorre alguma falha. O objetivo das chaves NF é isolar a falha para o menor número de pontos de consumo.
- **Chave de manobra/aberta:** São chaves normalmente abertas (NA), que podem ser fechadas com o objetivo de energizar setores da rede que podem ser isoladores de defeito.

1.2.1 Perdas em Sistemas de Distribuição de Energia Elétrica

Nos sistemas de energia elétrica, as perdas podem ser divididas em perdas comerciais e perdas técnicas. As perdas comerciais, ou perdas não-técnicas, refere-se à energia entregue aos pontos de consumo, porém não computada no faturamento da empresa de distribuição. Essas perdas ocorrem devido a erros de medição, furtos e fraudes. As perdas técnicas são dissipações de energia devido as resistências das linhas, (efeito Joule) durante o transporte e em equipamentos da rede.

Existem várias alternativas para redução de perdas técnicas em redes de distribuição, como a procura das melhores configurações de redes, gestão dos fluxos de energia reativa, melhorias físicas por substituição de cabos e equipamentos, otimização do planejamento das redes e a adoção de fontes de gerações distribuídas.

Neste trabalho, vamos estudar a reconfiguração de redes primárias para redução de perdas técnicas. A obtenção da melhor configuração para uma determinada rede consiste em encontrar os estados das chaves existentes na rede (aberta/fechada), que leve a configuração de mínimas perdas.

1.3 Reconfiguração de Redes para Redução de Perdas Técnicas em Redes Primárias de Distribuição Elétrica

As configurações dos sistemas de distribuição de energia elétrica são, quase sempre, operadas de forma radial com o propósito de reduzir custos e facilitar requisitos de proteção para operação da rede. Essas redes são caracterizadas por existir um único caminho energizado entre uma subestação (SE) e cada um dos pontos de consumo; usando-se a terminologia de grafos, não permite ciclos (Cavellucci 1998). A metodologia desenvolvida neste trabalho procura encontrar as melhores configurações para redes radiais onde existem gerações distribuídas com injeções aleatórias.

Os sistemas de distribuição podem configurar a topologia da rede alterando o estados das chaves, normalmente fechadas (NF) e normalmente abertas (NA). O problema de reconfigurações ótimas procura encontrar alternativas para reconfigurar a rede de distribuição através da troca dos estados de chaves, normalmente aberta ou normalmente fechada, procurando encontrar configurações radiais de menores perdas (Queiroz & Lyra 2009).

1.4 Revisão Bibliográfica

Esta seção apresenta a revisão bibliográfica sobre trabalhos que abordam o problema de redução de perdas técnicas em redes de distribuição de energia elétrica através de reconfigurações das redes ao longo das últimas décadas.

1.4.1 O trabalho pioneiro de Merlin & Back

Há mais de 40 anos, os engenheiros franceses Merlin & Back (1975) iniciaram a investigação para o problema de reconfiguração de redes. Os autores apresentaram duas alternativas para resolução do problema: uma abordagem exata, aplicável em redes de pequeno porte, e uma abordagem heurística, adotada nos exemplos com redes maiores. A alternativa exata proposta pelos autores utiliza o método “*branch-and-bound*”. A segunda alternativa é o procedimento heurístico de duas fases que ficou conhecido como “abertura sequencial de chaves”. A primeira fase consiste no fechamento de todas as chaves na obtenção de uma solução com mínimas perdas em uma rede com ciclos. Na segunda fase é aberta a chave pertencente ao ciclo que possui o menor fluxo de potência na solução de mínimas perdas com ciclos. As duas fases são repetidas até a obtenção de uma solução radial.

Uma ideia atraente implícita no trabalho de Merlin & Back é a possibilidade de reduzir perdas apenas por métodos matemáticos de exploração do conjunto de configurações, sem a necessidade de investimentos adicionais em equipamentos. O atrativo de obter benefícios sem custos expressivos, associado ao efeito demonstrativo dos métodos propostos no trabalho pioneiro de Merlin & Back impulsionaram as pesquisas na área de redução de perdas por reconfigurações em redes de distribuição.

As pesquisas discutidas nos próximos itens levaram a métodos capazes de resolver o problema em redes de porte real, a modelos mais detalhados e, mais recentemente, a consideração de geração distribuída com valores determinísticos. Este trabalho procura ampliar o conhecimento na área ao propor métodos de representação e de solução para redes com gerações distribuídas de características aleatórias.

1.4.2 Década de 80

Na década de 80, Civanlar et al. (1988) apresentam a heurística para reconfiguração de redes denominada “troca de ramos” (do inglês *branch-exchange*). Cada etapa dessa heurística realiza uma permuta de estados entre pares de chaves, uma aberta e outra fechada, de forma a obter redução de perdas. Os autores observaram que maiores reduções de perdas ocorrem quando se realiza operações de troca de ramos com arcos que estejam do lado de menor tensão, entre as tensões nos terminais de um arco aberto. Usando esta característica, o algoritmo realiza permutações de estados de chaves até o ponto em que

não é mais possível reduzir perdas – ou seja, até a obtenção da melhor solução sub-ótima alcançável pelo algoritmo.

Entre os primeiros artigos na área destacam-se, ainda na década de 80, os artigos de Baran & Wu (1989), Shirmohammadi & Hong (1989), Liu et al. (1989), Lee & Brooks (1988).

Baran & Wu (1989) estenderam a metodologia de “troca de ramos” desenvolvida por Civanlar et al. (1988), considerando como objetivo da otimização a redução de perdas e o balanceamento de cargas entre alimentadores. Baran e Wu estudaram também métodos para o cálculo de fluxos de potências em redes de distribuição radiais, considerando potências ativas e reativas – um aspecto curioso, é que o artigo de Baran e Wu, embora denso e rico em informações para compreensão do problema de reconfiguração de redes, é citado principalmente como referência de informações sobre os atributos da rede de porte muito pequeno usada para exemplificar a aplicação das ideias discutidas no artigo.

Shirmohammadi & Hong (1989) aperfeiçoaram a proposta de Merlin & Back (1975), desenvolvendo um método heurístico que considera potências ativas e reativas, incluindo também a verificação de quedas de tensões no processo de abertura sequencial de chaves.

Aoki et al. (1987) formularam um problema não-linear convexo para resolver problemas de programação quadrática até encontrar a configuração de mínimas perdas. Liu et al. (1989) utilizaram os limites de fluxos e quedas de tensão formulados por Aoki et al. (1987) e propuseram técnicas de otimização não-linear associadas a heurísticas, mas utilizando ideias alternativas às exploradas por Merlin & Back (1975). O procedimento é realizado para dois alimentadores de cada vez.

Todos os trabalhos mencionados consideravam o problema de reconfiguração com demandas conhecidas e com valores fixos. No entanto, já em 1988 Lee & Brooks (1988) abordaram o problema de reconfiguração ótima associado a alocação ótima de capacitores sob a hipótese de demandas variáveis ao longo do período estudado. Os estudos de casos mostraram que é possível obter maiores reduções de perdas quando as configurações são modificadas para melhor se adaptarem às variações nos valores das cargas.

1.4.3 Década de 90

Na década de 90, muitos novos trabalhos abordaram o problema de reconfiguração de redes, explorando novas heurísticas e ideias que começavam a ser exploradas em problemas de otimização, como conceitos desenvolvidos na área de inteligência artificial e metaheurísticas para abordagem de problemas de otimização combinatória.

Taylor & Lubkeman (1990) propuseram o uso de sistemas especialistas para otimizar as configurações de redes, procurando eliminar sobrecargas de transformadores e reduzir perdas. Nara et al. (1992) desenvolveram metodologia baseada em algoritmos genéticos para construir uma população de soluções com as melhores configurações de redes.

Cavellucci & Lyra (1997) estenderam as ideias de Merlin & Back (1975) em um método de duas fases, baseado em gradiente reduzido para redes e buscas informadas, desenvolvidas com conceitos da área de inteligência artificial – a abertura de chaves é guiada pelas buscas informadas que utilizam informações de distribuições ótimas de fluxos obtidas pelo algoritmo gradiente reduzido para redes malhadas. McDermott et al. (1999) desenvolveram um método heurístico construtivo onde todas as chaves são inicialmente abertas, e fechadas gradualmente até a obtenção de uma rede radial.

1.4.4 Após 2000

As pesquisas na primeira década dos anos 2000 procuraram explorar as possibilidades de encontrar melhores soluções através de novas metaheurísticas, como, por exemplo, *otimização por colônia de formigas*, *GRASP* (acrônimo da expressão em inglês *Greedy Randomized Adaptive Search Procedure*) e *busca harmônica*. Outros aspectos a destacar foi a proposta de modelos para abordar o problema de variações de demandas ao longo do período de estudo e a abordagem do problema de reconfiguração ótima em redes de porte real.

A abordagem do problema com variações de demandas foi retomada com os trabalhos de Vargas et al. (2004), Bueno et al. (2004) e Queiroz & Lyra (2009). Vargas et al. (2004) exploraram o uso de sistemas classificadores para supervisionar redes em tempo real e realizar reconfigurações sempre que forem identificadas variações significativas de demandas. Bueno et al. (2004) propuseram uma nova formulação para o problema que considera explicitamente as variações de demandas, mas impede reconfigurações ao longo do período de estudo. Queiroz & Lyra (2009) desenvolveram um algoritmo genético híbrido adaptativo para resolver o problema proposto por Bueno et al. (2004) em redes de porte real.

A partir dos anos 2000 começaram a ter registro os esforços de instituições de governo e acadêmicas para desenvolver o conjunto de tecnologias que permitiria implantar gerações distribuídas em larga escala nas redes de distribuição. O conjunto dessas tecnologias veio a tornar-se conhecido com a expressão aglutinadora *Smart Grid* – a evolução dos conceitos de *Smart Grid* até 2010 é historiada no artigo de Lightner e Widergren, publicado no primeiro número da revista *IEEE Transactions on Smart Grid*, Lightner & Widergren (2010). Recentemente, a literatura sobre o problema de reconfiguração de redes tem procurado considerar da existência de geração distribuída nas redes, mas res-

trita ao caso mais simples de gerações com injeções controláveis (usa-se com frequência o termo *gerações despacháveis*) – logo, com valores determinísticos conhecidos. Trabalhos como Wu et al. (2010), Ochoa & Harrison (2011), Bernardon et al. (2012), Ramaswamy & Deconinck (2012), Franco et al. (2013), Rao et al. (2013), Rosseti et al. (2013), Tahboub et al. (2015), Possemato et al. (2016) e Jagtap & Khatod (2016) exploram o problema de reconfiguração de redes com geração distribuída determinística.

Wu et al. (2010) estudaram o problema de minimizar as perdas e melhorar o equilíbrio de cargas em redes com gerações distribuídas controláveis usando uma pequena rede de 33 nós como plataforma de experimentos. O processo de otimização é realizado com algoritmo de colônia de formigas; os resultados mostraram que a redução de perdas e o balanceamento de cargas foram mais expressivos quando a geração distribuída é usada para complementar os benefícios das reconfigurações.

Ochoa & Harrison (2011) exploram o uso de fluxo de potência linearizado e a presença de geração distribuída. Os autores mostraram o impacto significativo da variação do tempo nas perdas de energia. A abordagem é avaliada em uma rede radial com 61 nós.

Bernardon et al. (2012) apresentam um método heurístico *fuzzy* multicritério de tomada de decisão para reconfiguração automática na rede de distribuição usando geração distribuída. O método foi testado numa rede real localizada no Brasil, e possui 20 subestações, 125 alimentadores, 214 interruptores e fornece energia para mais de 520,000.00 consumidores.

Ramaswamy & Deconinck (2012) propõem o uso de um algoritmo genético multiobjetivo (NSGA-II), para uma rede pequena com 16 nós, e comentam as vantagens proporcionadas ao inserir gerações distribuídas na rede.

Franco et al. (2013) representaram o problema de reconfigurações com gerações distribuídas controláveis por um modelo linear com variáveis inteiras, o que permite usar no processo de otimização os bons códigos atuais para solução de problemas de programação linear mista; a abordagem foi avaliada em redes com 69 e 417 nós.

Rao et al. (2013) utilizaram um algoritmo de *busca harmônica* para estudar o problema em redes com gerações distribuídas controláveis; estudos de casos demonstrativos utilizaram redes com 33 e 69 nós e consideraram cinco cenários para analisar o método proposto. O primeiro cenário é o caso base, onde o sistema é considerado sem a reconfiguração e a geração distribuída. O segundo cenário é igual ao primeiro cenário, exceto que a reconfiguração do sistema é considerada. O terceiro cenário é igual ao primeiro cenário, porém incluindo a geração distribuída. No quarto cenário as unidades de geração distribuída são consideradas logo após a reconfiguração da rede. Os autores compararam os resultados da busca harmônica com uma alternativa de solução por algoritmos genéticos Nara et al. (1992), Zhu (2002).

Rosseti et al. (2013) propuseram um algoritmo heurístico baseado em índices de sensibilidade para estudar o problema de reconfigurações com gerações controláveis; a

metodologia foi avaliada em redes com 16, 33 e 94 nós. Um estudo semelhante foi realizado por Esmailian & Fadaeinedjad (2015), usando uma metaheurística híbrida para encontrar soluções em redes de 33 e 83 nós.

Tahboub et al. (2015) representaram o problema por um modelo não-linear com variáveis inteiras e incluem na representação as variações de potência ativa e reativa; as soluções são obtidas por código de otimização não linear mista, em redes demonstrativas de 33 e 84 nós.

Possemato et al. (2016) propõem um algoritmo genético para estudar o impacto da inserção de fontes de gerações distribuídas no problema de redução de perdas de energia elétrica. Os testes foram realizados em uma rede real italiana que cobre aproximadamente 29.000 km, fornecendo energia para 2,7 milhões de consumidores.

Jagtap & Khatod (2016) estudaram a redução de perdas por reconfigurações com cenários alternativos para o uso de geração distribuída controlável; as soluções foram obtidas por método heurístico em redes com 9 e 33 nós.

Das et al. (2016) apresentam um estudo de reconfiguração das redes de distribuição com geração distribuída, considerando as variações de carga. Uma análise de sensibilidade baseada no índice de estabilidade de tensão é utilizado para obter a localização ideal da unidade de geração distribuída. A reconfiguração de rede é baseada na redução real da perda de potência, considerando o modelo de carga residencial com variação de tempo dependente da tensão. A metodologia proposta é apresentada em uma rede de 33 nós.

Em síntese, a leitura dos trabalhos acima mencionados indica que o estudo do problema de encontrar configurações ótimas de redes radiais de distribuição com a presença de geração distribuída está ainda numa fase exploratória, restrita a cenários de gerações controláveis em redes muito pequenas – os estudos realizados por Franco et al. (2013) consideram uma rede com 417 nós, cerca de 5 vezes maior do que redes consideradas nos outros trabalhos, mas ainda assim distante de situações de porte real, com alguns milhares de nós e arcos.

Este trabalho propõe um passo adicional na discussão sobre o problema de reconfigurações de redes radiais de distribuição, ao incluir a representação de aspectos aleatórios de gerações distribuídas, decorrentes do uso crescente de fontes renováveis baseadas em energia solar e eólica. Essas fontes são denominadas não controláveis, pois as disponibilidades de energia primária para produção de energia elétrica sofrem fortes variações ao longo de um dia, como ilustra a Figura 1.3.

1.5 *Smart Grid*

O artigo de Lightner & Widergren (2010) publicado no primeiro número da revista *IEEE Transactions on Smart Grid* em 2010 apresenta a evolução dos conceitos de




Figura 1.3: Gráfico característico de velocidade de ventos para geração eólica. Fonte: Oliveira (2014).

Smart Grid e seu histórico. Segundo os autores um dos principais aspectos da visão de *Smart Grids* é a capacidade de sinergia, coordenando vários recursos para realizar uma função específica. Nos últimos anos, a estrutura dos sistemas de distribuição de energia elétrica tem passado por grandes mudanças com a incorporação de tecnologias associadas ao conceito de *Smart Grid*. Estas mudanças no sistema de distribuição permitem uma maior diversidade de serviços relacionados à energia, como gestão da demanda, o uso de geração distribuída a partir de fontes renováveis, a conexão de veículos elétricos, entre outros (Bernardon et al. 2014). A Figura 1.4 ilustra uma rede de distribuição com componentes de *Smart Grid*: geração distribuída por painéis solares, geração distribuída eólica, armazenamento de energia em baterias e controlador, que procura gerenciar a rede de forma inteligente (*smart*).

Em grandes linhas, o conjunto de componentes que caracterizam as *smart grids* procuram inovações em eficiência e sustentabilidade, proporcionadas principalmente por fontes sustentáveis de geração distribuída. Além de possibilitar a redução das perdas técnicas e o uso de combustíveis não renováveis, outros benefícios proporcionados pela inserção de geração distribuída incluem a possibilidade de adiar a substituição de equipamentos, o aumento da confiabilidade das redes e a melhora nos níveis de tensão nos horários de maior consumo de energia.

Os principais componentes associados ao conceito de *smart grids* em redes de distribuição são apresentados a seguir (Bernardon et al. 2016).

- **Energia eólica:** A obtenção da energia eólica é feita a partir da conversão de energia cinética das massas de ar através do movimento de translação em energia cinética rotativa, utilizando uma turbina eólica ou gerador eólico para geração de eletricidade.
- **Energia fotovoltaica:** A geração fotovoltaica é gerada a partir da conversão direta da energia solar em energia elétrica através de células solares (fotovoltaicas). As




Figura 1.4: Rede de distribuição com componentes de *Smart Grid*. Fonte: imagem baseada em *IEEE PES Smart Grids* (2016).

principais variáveis que afetam a potência gerada pelas células fotovoltaicas são a radiação solar e a temperatura.

- **Armazenamento por baterias:** Energia armazenada consiste em um estágio intermediário entre sua produção e consumo. O armazenamento diminui a exportação da energia gerada para o sistema de distribuição, e envia parte da energia gerada para um dispositivo de armazenamento, como baterias. As vantagens de armazenar energia são: guardar a energia quando essa é gerada em excesso, e utilizá-la quando o fornecimento não for o suficiente.
- **Veículos elétricos *plug-in*:** Os veículos elétricos são caracterizados pela substituição de motores de combustão interna por motores elétricos alimentados por baterias. As baterias dos veículos chamados *plug-in* são recarregas através da rede de distribuição elétrica.

CAPÍTULO 2

CARACTERIZAÇÃO E FORMULAÇÃO DO PROBLEMA

“I’ll take you down the only road I’ve ever been down
You know the one that takes you to the places
Where all the veins meet, yeah.”

The Verve - *Bitter Sweet Symphony* (1997).

Este capítulo explora as características do problema em uma rede maquete de referência, projetada para realçar as consequências da presença de gerações aleatórias nas redes. Em seguida, é proposto um modelo matemático para o novo cenário de encontrar configurações ótimas de redes radiais de distribuição.

2.1 Representação por Grafos de Redes de Distribuição de Energia Elétrica

Uma rede de distribuição de energia elétrica pode ser representada por grafos (Ahuja et al. 1993). Segundo Queiroz & Lyra (2009), essa representação é conveniente por ser uma abstração intuitiva para a rede e pela possibilidade de implementar algoritmos eficientes utilizando resultados e estruturas de dados da área de grafos.

Um grafo $G = (N, A)$ é composto de um conjunto finito não vazio de nós (conjunto N) e outro conjunto de relações binárias entre os elementos de N (conjunto A). O problema de encontrar a melhor configuração pode ser caracterizado como a procura de uma árvore geradora $G = (N, A')$ de custo mínimo para atender as demandas de energia nos nós de uma rede primária de distribuição de energia elétrica, onde N é formado pelo conjunto de nós e A' o conjunto de arcos da rede que participam da árvore.

A rede de distribuição apresentada na Figura 2.1 ilustra os principais componentes para abordagens do problema de redução de perdas técnicas: disjuntores, religadores e chaves (arcos), pontos de cargas (nós), linhas elétricas (arcos) e subestação (nós).

Como as redes de distribuição operam com configurações radiais, o problema de encontrar a configuração ótima para uma rede ao longo de determinado período corresponde a encontrar a árvore geradora da rede que permita atender às demandas ao longo do período em estudo com as menores perdas possíveis. As variáveis de decisão que definem as árvores geradoras são os estados das chaves existentes na rede (abertas ou fechadas), como ilustra a Figura 2.1.




Figura 2.1: Exemplo de configuração de operação e de reconfiguração por chaveamentos em uma rede de distribuição.

2.2 Limitante Superior para o Número de Configurações das Redes

O número de configurações possíveis cresce fatorialmente com a dimensão da rede, caracterizando um problema difícil de otimização combinatória (Bueno 2000). A Equação (2.1) apresenta o cálculo do limitante superior L_S para o número de configurações possíveis da rede, supondo que existam um total de p chaves e são necessárias m chaves fechadas para manter a rede conexa e radial. De outra forma, L_S são todas as combinações possíveis com m chaves fechadas e $p - m$ chaves abertas. O parâmetro L_S é um limitante superior porque além de considerar as possíveis configurações factíveis, inclui as configurações infactíveis, ou seja, redes não radiais (e não conexas).

$$L_S = \frac{p!}{m!(p-m)!} \quad (2.1)$$

2.3 Problema Maquete de Referência

Alguns aspectos fundamentais do problema de encontrar configurações ótimas de redes de distribuição de energia elétrica com gerações distribuídas de valores aleatórios pode ser estudado em um problema reduzido de referência, desenvolvido a partir do problema apresentado em Queiroz (2005). Este problema de referência é definido para uma rede com 7 nós (6 nós de carga e uma subestação no nó 1) e 9 arcos ilustrado na Figura 2.2. Os arcos representam as linhas de distribuição com suas respectivas chaves (supõe-se que as linhas que partem da subestação não possuem chaves).




Figura 2.2: Rede Maquete – Caso Base

O primeiro nó do grafo está associado à subestação, que fornece toda a potência necessária à rede, ou a potência complementar quando fontes distribuídas de energia são conectadas à rede. As demandas nos nós j ($j = 2, \dots, 7$), d_j (em ampères) são dadas na Tabela 2.1. O total das perdas de energia na rede é obtido pela fórmula $\sum_{k \in \mathcal{A}} r_k (i_k)^2$ *Watts*, onde \mathcal{A} é o conjunto de arcos (de linhas), r_k é a resistência da linha k , e i_k é o fluxo de corrente na linha k . Nesta rede maquete supõe-se que todas as linhas possuem uma resistência de 1 *ohm*; portanto, o cálculo da perda de energia total pode ser simplificado em $\sum_{k \in \mathcal{A}} (i_k)^2$ *Watts*.

Demandas (ampères)					
d2	d3	d4	d5	d6	d7
4	2,5	12	2	2	1,5

Tabela 2.1: Demandas nos nós.

Supondo que as linhas podem transportar as correntes para atender as demandas para todas as configurações de redes possíveis e que todas as linhas que não estão conectadas à subestação têm um disjuntor, há apenas 11 configurações de redes factíveis (árvore geradora mínima). Portanto, uma solução ótima global para o problema de reconfiguração de redes pode ser obtida por busca exaustiva sobre o espaço de soluções. Se nenhuma fonte de geração estiver conectada à rede, a configuração apresentada na Figura 2.2 é a solução ótima, com $\sum_{k \in \mathcal{A}} (i_k)^2 = 510,5$ *Watts*.

Considere agora uma fonte de energia aleatória no nó 4 com uma função de distribuição discreta e apenas 3 valores possíveis para as gerações (9, 15, e 18 *ampères*), com as respectivas probabilidades apresentadas na Tabela 2.2.

Geração (<i>ampères</i>)	Probabilidade
$g_a = 9$	$p_a = 0,2$
$g_b = 15$	$p_b = 0,5$
$g_c = 18$	$p_c = 0,3$

Tabela 2.2: Probabilidades de valores de geração.

Uma primeira abordagem para modelar a fonte de energia aleatória seria considerar um valor de geração constante, $\bar{g} = p_a \cdot g_a + p_b \cdot g_b + p_c \cdot g_c = 14,7$ *ampères*. A Figura 2.3 mostra a configuração da rede ideal para esta abordagem, com $\sum_{k \in \mathcal{A}} (i_k)^2 = 58,7$ *Watts*, como o valor ótimo correspondente estimado para as perdas. Note que este valor é inferior ao caso anterior, que não possuía fonte de geração. De fato, este resultado poderia ser antecipado, uma vez que a fonte está conectada ao nó com maior demanda, fazendo com que os fluxos de corrente diminuam.




Figura 2.3: Configuração ótima para geração constante correspondente ao valor esperado das injeções.

A abordagem de representar a injeção da fonte de energia aleatória pelo seu valor esperado pode ser adequada se as variações nas gerações forem pequenas ou quando os valores das injeções de energia não forem significativos em relação às demandas na rede. No entanto, esta abordagem está associada a uma suposição de linearidade que não é adequada quando as variações das injeções das gerações distribuídas forem significativas, quando comparadas com os valores de demanda, como no caso apresentado. A existência de um grande número de configurações de redes factíveis para o problema acrescenta argumentos adicionais para se evitar a modelagem de injeções aleatórias de energias por seus valores esperados.

Uma abordagem mais adequada para o problema deve deixar de lado o pressuposto de que as perdas mudam linearmente com variações nos valores de energias aleatórias e minimizar formalmente o valor esperado para as perdas, dado neste caso

por $p_a \cdot (\sum_{k \in \mathcal{A}} (i_k^a)^2) + p_b \cdot (\sum_{k \in \mathcal{A}} (i_k^b)^2) + p_c \cdot (\sum_{k \in \mathcal{A}} (i_k^c)^2)$, onde i_k^a , i_k^b e i_k^c são, respectivamente, os fluxos em uma dada configuração de rede para cada valor possível da injeção aleatória de energia (g_a , g_b e g_c). A Figura 2.4 apresenta a configuração ótima da rede para esta alternativa de modelagem, que leva a 82,1 *Watts*, como valor ótimo esperado para as perdas. Este valor é 40,5% superior a 58,7 *Watts*, obtido quando a injeção de energia aleatória é modelada como uma constante igual ao valor esperado; a diferença de valores enfatiza o fato de que a modelagem de uma fonte de energia aleatória pelo valor médio pode não corresponder à realidade. Observe também que as diferentes alternativas de modelagem levam a configurações ótimas distintas; se calcularmos o valor esperado das perdas para a configuração ótima com geração constante, representada na Figura 2.3, encontraremos o valor de 88,1 *Watts*, ou seja, 7,3% acima do valor obtido com a configuração ótima representada na Figura 2.4




Figura 2.4: Configuração ótima para os valores esperados de perdas.

O estudo com o problema maquete permite algumas observações preliminares:

1. A presença de geração distribuída com valores aleatórios requer modelos mais ricos para o problema de reconfiguração de redes;
2. Quando fontes de energia com valores aleatórios estão presentes em uma rede de distribuição, as perdas de energia geralmente diminuem; embora seja possível conceber contra-exemplos para os quais as perdas de energia aumentam com a existência de gerações distribuídas, esses casos devem ser interpretados como alertas para a necessidade de reforçar as redes, pois resultam da alocação das fontes em áreas onde as linhas estão subdimensionadas para suportar os aumentos de fluxos (voltaremos a discutir esse aspecto no Capítulo 5);
3. As configurações ótimas para as redes podem ser diferentes em cenários sem fontes de energia distribuídas; em cenários com fontes representados pelas injeções médias e em cenários onde as aleatoriedades das fontes são formalmente representadas;
4. Se o valor de uma fonte de energia aleatória é significativo em relação às demandas e variações são grandes, modelar as fontes aleatórias pelos seus valores esperados

pode levar a configurações de redes inadequadas e à subestimação das perdas esperadas; portanto, o problema de reconfiguração de redes deve modelar formalmente as aleatoriedades das fontes de gerações distribuídas.

A próxima seção, apresenta o modelo matemático proposto para o problema de reconfiguração de redes, baseada nas ideias do estudo com a rede maquete discutidas na Seção 2.3.

2.4 Formulação Matemática do Problema

Para enfatizar os novos aspectos introduzidos no problema de reconfiguração de redes pela existência de injeções aleatórias de energia, apenas uma fonte de energia com injeções aleatórias é considerada no modelo matemático a seguir (a generalização para um número maior de fontes de energia é imediata). Além disso, para evitar a necessidade de considerar aspectos formais desnecessários no contexto de estudo do problema, supõe-se que a fonte de energia aleatória tem uma função de distribuição discreta e um espaço finito para os valores possíveis de injeções aleatórias. Sob tais suposições, o problema de reconfiguração de redes pode ser representado pelas Equações (2.2)-(2.7), apresentadas a seguir.

$$\text{Min}_{s_k \in \mathcal{S}} \left[\sum_{i \in \mathcal{I}} p_i \cdot l_i(P, Q, V) \right] \quad (2.2)$$

sujeito a

$$s_k \in \{0, 1\} \quad (2.3)$$

$$l_i(P, Q, V) = \sum_{k \in N} r_k \frac{(P_k^i)^2 + (Q_k^i)^2}{(v_k^i)^2} \quad (2.4)$$

$$\forall i \in \mathcal{I}, \forall k \in N \quad \begin{cases} P_k^i = \sum_{j \in A_k} P_{k,j}^i + P_{L_k} - P_i \cdot z_k \\ Q_k^i = \sum_{j \in A_k} Q_{k,j}^i + Q_{L_k} - Q_i \cdot z_k \\ z_k \in \{0, 1\} \end{cases} \quad (2.5)$$

$$\forall i \in \mathcal{I}, \forall k \in N \quad \begin{cases} (v_{k+1,j}^i)^2 = (v_k^i)^2 - \\ -2(r_{k+1,j} P_{k+1,j}^i + x_{k+1,j} Q_{k+1,j}^i) \end{cases} \quad (2.6)$$

$$G' = (N, A') \text{ é uma árvore} \quad (2.7)$$

onde s_k representa o estado da chave associado ao arco k (fechado se $s_k = 1$ e aberto se $s_k = 0$), \mathcal{I} é o conjunto de valores possíveis para injeções de geração aleatória; p_i é

a probabilidade de ter a injeção de potência ativa P_i e potência reativa Q_i pela fonte aleatória; $l_i(P, Q, V)$ é o total de perdas técnicas na rede, quando a potência ativa P_i e a potência reativa Q_i são injetadas pela fonte de energia aleatória; N é o conjunto de nós da rede; r_k é a resistência da linha k , P_k^i , Q_k^i , e v_k^i são, respectivamente, a potência ativa e a potência reativa que flui no arco k , e o valor da tensão no nó k , quando a potência ativa P_i e a potência reativa Q_i são injetados pela fonte de geração aleatória; A_k é o conjunto de arcos com origem no nó k ; $P_{k,j}^i$ e $Q_{k,j}^i$ são, respectivamente, a potência ativa e reativa que fluem nos arcos “ k, j ”, *sucessores* do nó k na *árvore* que representa o alimentador (veja Figura 2.5), quando a potência ativa P_i e a potência reativa Q_i são injetados pela fonte de geração aleatória; P_{L_k} e Q_{L_k} são, respectivamente, cargas de potência ativa e reativa no nó k ; $z_k = 1$ se a fonte de geração estiver conectada ao nó k , e $z_k = 0$ caso contrário.




Figura 2.5: Conjunto de arcos saindo do nó k .

G' é um subgrafo que inclui todos os nós da rede e A' é o subconjunto do conjunto de arcos A que inclui todos os arcos com fluxos não-zero para todos os valores possíveis da potência ativa P_i e potência reativa Q_i injetada pela fonte aleatória.

As Equações (2.5)-(2.6) são generalizações das equações simplificadas denominadas DistFlow, estudadas em Baran & Wu (1989). Embora não haja restrições para a adoção de equações mais detalhadas (mesmo para equações de redes trifásicas), as equações simplificadas ajudam a orientar o foco para aspecto principal estudado neste trabalho, que é o impacto de gerações distribuídas aleatórias no problema de reconfiguração de redes.

Observe que a generalização do problema de reconfiguração de redes para incluir um maior número de injeções de energia aleatórias é simples. Basta considerar o efeito das outras fontes na função objetivo e nas Equações (2.5)-(2.6). No entanto, muitas fontes aleatórias podem transformar o problema intratável para redes em escala real; nesse caso, seria necessária uma elaboração adicional do modelo com técnicas de aproximação e agregação.

Como o problema caracterizado pelas Equações (2.2)-(2.7) é um problema de otimização combinatória com equações não lineares e não convexas, uma aborda-

gem de otimização combinatória evolutiva chamada *biased random-key genetic algorithm* (BRKGA) foi desenvolvida neste trabalho para resolver o problema.

CAPÍTULO 3

ALGORITMOS GENÉTICOS BASEADOS EM CHAVES ALEATÓRIAS

“I know, nobody knows
Where it comes and where it goes
I know it’s everybody’s sin
You got to lose to know how to win.”

Aerosmith - *Dream on* (1972).

Neste capítulo, é apresentado uma introdução à teoria dos algoritmos genéticos. São descritos os conceitos básicos e o funcionamento desta metaheurística e, em seguida, é apresentado o novo algoritmo genético para problemas de otimização combinatória, denominado algoritmos genéticos baseados em chaves aleatórias, método de otimização escolhido para resolver o problema de reconfiguração de redes.

3.1 Conceito Básicos

Algoritmos genéticos (AGs) são uma classe de algoritmos evolutivos (Bäck et al. 2000) inspirados na teoria da evolução das espécies proposta pelo naturalista britânico Darwin (1859). As primeiras pesquisas relacionadas aos algoritmos genéticos foram formalizados, inicialmente, por Holland (1975), que propôs simular etapas do processo evolutivo das espécies incorporando-as em um algoritmo computacional. Essas ideias foram registradas no livro “*Adaptation in Natural and Artificial Systems*”, publicado em 1975. Na década de 80, Goldberg (1989) obteve sucesso ao aplicar os AGs na área industrial; desde então, esta técnica é utilizada para solucionar problemas reais de otimização combinatória.

Na representação dos algoritmos genéticos, os indivíduos são caracterizados por cromossomos, uma cadeia de genes que codificam uma possível solução do problema. A codificação é definida pelos alelos, que são valores possíveis para cada uma das posições dos

genes do cromossomo. Cada indivíduo contém a codificação (genótipo) de uma possível solução do problema (fenótipo) (Fogel 1995). O genótipo codifica as informações genéticas dos indivíduos e o fenótipo decodifica as características representadas no genótipo.

O funcionamento do algoritmo genético, apresentado em Holland (1975), inicia-se com a geração da população inicial de indivíduos $P(0)$ – genótipos, gerados aleatoriamente. Cada indivíduo corresponde a uma solução do problema e a qualidade de cada indivíduo é dada pelo *fitness*. Alguns desses indivíduos são selecionados para o *crossover* de forma probabilística, procurando-se assegurar que cada indivíduo tenha uma probabilidade proporcional à qualidade indicado por seu *fitness*. Portanto, os melhores indivíduos têm mais chances de reproduzir suas heranças genéticas durante o processo evolutivo. Em seguida, são aplicados operadores genéticos de *crossover* e mutação que levam a modificações na população e consequente exploração do espaço de soluções, procurando identificar soluções de melhor qualidade. O processo se repete até que um critério de parada seja satisfeito. A seguir, é apresentado o pseudocódigo de um algoritmo genético básico, proposto por Holland (1975).

Algoritmo 1: Funcionamento de um AG básico.

$i = 0$;

Gerar uma população inicial $P(i)$;

Avaliar $P(i)$;

enquanto *condição de parada não for satisfeito* **faça**

$i = i + 1$;

 Selecionar indivíduos de $P(i)$;

 Cruzar indivíduos selecionados;

 Mutar indivíduos;

 Avaliar indivíduos gerados;

fim

Os principais componentes dos algoritmos genéticos são descritos a seguir.

3.1.1 Representação do Cromossomo

A representação ou codificação das soluções do problema de otimização (fenótipos) em cromossomos (genótipos) são um conjunto de parâmetros que definem as características associadas aos genes, agrupados de forma a caracterizar um cromossomo. Essas características são importantes para o desempenho dos algoritmos genéticos e sua estrutura são vetores de tamanho fixo ou variável.

A representação das soluções no problema de redução de perdas em redes de distribuição devem levar a redes com topologia em árvore (*minimum spanning tree*).

A primeira representação adotada para abordar o problema de reconfiguração de redes de distribuição por algoritmos genéticos foi a *Characteristic Vectors* (Nara et al.

1992), onde cada gene possui um valor binário (0 ou 1), indicando o estado da chave. Se o arco está aberto, então o gene possui valor “0”, senão “1” está fechado. No entanto, esta representação pode gerar soluções infactíveis após a aplicação dos operadores genéticos *crossover* e mutação (Queiroz 2005).

Na representação *Network Random Keys* (NRK) cada posição representa um arco da rede, e cada arco dentro do genótipo possui um peso; a partir desses pesos, gera-se fenótipo factível através da solução de uma árvore geradora de custo mínimo (Queiroz 2005). Esta representação é adotada neste trabalho, e será detalhada no próximo capítulo.

A Tabela 3.1 apresenta um cromossomo codificado pela representação *Characteristic Vectors* e *Network Random Keys*, e o fenótipo do cromossomo de tamanho igual ao número de arcos é ilustrado na Figura 3.1.

Representações	Arcos								
	1	2	3	4	5	6	7	8	9
<i>Characteristic Vectors</i>	1	1	0	1	1	0	1	0	1
<i>Network Random Keys</i>	29	9	85	15	43	55	34	72	23

Tabela 3.1: Cromossomos codificados por *Characteristic Vectors* e NRK.




Figura 3.1: Árvore codificada.

3.1.2 Inicialização da População

Como já mencionado, a abordagem mais usual para a criação da população inicial de algoritmos genéticos é produzir indivíduos de forma aleatória. Em soluções de problemas reais, existe também a alternativa de obter informações disponíveis para o problema, e procurar utilizá-los na criação de uma população inicial de boa qualidade, com a expectativa de acelerar o processo de obtenção das melhores soluções.

3.1.3 Função de Avaliação

A função de avaliação determina a qualidade das soluções dos indivíduos da população. A avaliação de um cromossomo é feita de acordo com o valor *fitness*, termo

inspirado na propensão de um indivíduo sobreviver e reproduzir-se em um determinado ambiente. Em algoritmos evolutivos, a função de avaliação está relacionada ao valor da função objetivo da solução representada pelo indivíduo.

Neste trabalho a função de avaliação está relacionada a função objetivo, que caracteriza as perdas numa rede de distribuição de energia elétrica. O melhor valor de *fitness* é dado pelo indivíduo que proporcionar maior redução de perdas.

3.1.4 Seleção

O processo de seleção está associado a forma de escolha de indivíduos da população que participarão do processo evolutivo, para gerar descendentes através de *crossover*; esses indivíduos farão parte da população na geração seguinte.

Após a avaliação do *fitness*, é feita uma seleção de forma probabilística, onde os indivíduos com maior valor de *fitness* têm maior probabilidade de participar do processo evolutivo, procurando-se proporcionar a melhor qualidade da população a cada geração. Existem vários métodos para implementar o operador de seleção, como a *roleta* (Goldberg 1989), *ranking* (Fogel 1995) e o método de seleção por *torneio* (Bäck et al. 2000).

No método de seleção por roleta, a chance de seleção de um indivíduo é proporcional ao seu valor de *fitness*. A roleta tende a escolher o indivíduo que possui maior valor de *fitness*, pois este indivíduo é representado na roleta por uma área proporcional a sua qualidade.

Por exemplo, a Tabela 3.2 apresenta os dados dos indivíduos que participam do método de seleção por roleta apresentado na Figura 3.2.

Indivíduo	<i>Fitness</i>	Participação (%)
1	169	14.4
2	576	49.2
3	64	5.5
4	361	30.9

Tabela 3.2: Dados de indivíduos que participarão do método de seleção roleta.

Outro método de seleção é o *ranking*, ou *rank-based*, que ordena a classificação dos indivíduos de acordo com o valor do *fitness* da população atual e determina a probabilidade de seleção (Fogel 1995). Se a função objetivo do problema é de minimização, então a classificação é em ordem crescente, caso contrário, se a função objetivo do problema é maximizar, então é em ordem decrescente.

No método de seleção por *torneio* são escolhidos n indivíduos da população de forma aleatória, e estes indivíduos podem ser substituídos ou não na população. Os torneios podem ser realizados entre dois indivíduos (torneio binário), ou generalizado para um tamanho n arbitrário de indivíduos (tamanho do torneio). O indivíduo que possui melhor valor de *fitness* vence o torneio e é escolhido para ser inserido na próxima geração.




Figura 3.2: Seleção pelo método da roleta de acordo com os dados apresentados na Tabela 3.2.

A seguir, o método *torneio* é apresentado em um pseudocódigo, onde os indivíduos podem ser substituídos da população e o vencedor é selecionado de forma determinística (Bäck et al. 2000).

Algoritmo 2: Funcionamento método de seleção por torneio.

Entrada: População(i) $\in I^\lambda$, tamanho do torneio $n \in \{1, 2, \dots, \lambda\}$

Saída: População depois da seleção $P(i)'$

torneio(n, a_1, \dots, a_λ);

para $j = 1$ **até** λ **faça**

a'_j = indivíduo com melhor valor de *fitness* de n escolhido de $\{a_1, \dots, a_\lambda\}$;

fim

retorna $\{a'_1, \dots, a'_\lambda\}$;

3.1.5 Estratégia Elitista

No mecanismo de seleção, há a opção de manter na população seguinte o melhor indivíduo, ou os n melhores indivíduos da população atual, com o intuito de preservar as melhores soluções e também passar a herança genética para as próximas gerações, na tentativa de encontrar as melhores soluções existentes no espaço de soluções. Essa estratégia é conhecida como *seleção elitista* (Bäck et al. 2000). Normalmente o elitismo é realizado após a avaliação do *fitness*; cada indivíduo é ordenado de acordo com o valor do *fitness* e o melhor, ou os melhores, são salvos para participar do processo evolutivo da próxima geração.

3.1.6 Operadores Genéticos

Como já observado, nos AGs os indivíduos representam uma possível solução do problema. Esses indivíduos podem ser representados de várias formas, e a qualidade da solução associada a cada um deles é determinada pela função de avaliação, é associada à função objetivo do problema. Após a avaliação de cada solução, alguns dos indivíduos da nova população são selecionados para sofrerem transformações por meio dos operadores genéticos, formando novas soluções. Este processo é realizado através dos operadores genéticos *crossover* e mutação, descritos a seguir.

Crossover

O *crossover* é um operador genético que atua entre cromossomos de um dado par de soluções (Bäck et al. 2000). Durante este processo, dois indivíduos realizam a recombinação de material genético, e este é herdado por seus descendentes, com o objetivo de contribuir para a melhoria e diversificação da população. Quando as recombinações levam a indivíduos infactíveis, é necessário incluir métodos capazes de transformar indivíduos infactíveis em soluções factíveis. Também existem técnicas que procuram lidar com indivíduos infactíveis, mantendo-os na população. Entretanto, essas manipulações normalmente não são atrativas para implementações, devido ao alto custo computacional; o ideal é que o *crossover* leve sempre a criação de novos indivíduos factíveis.

A primeira ideia de recombinação denominada *crossover* de um ponto foi introduzida por Holland (1975). Neste operador, dois indivíduos são escolhidos a partir do método de seleção e cada cromossomo é dividido em um ponto, escolhido aleatoriamente. Uma parte do corte do cromossomo de um dos pais é recombinado com a outra parte do corte do cromossomo do outro pai, gerando dois descendentes. Uma generalização do *crossover* de um ponto é o *crossover* de n pontos (De Jong 1975). São realizados n cortes aleatoriamente no cromossomo dos dois pais escolhidos, e a recombinação é a troca intercalada entre os cortes dos dois pais, gerando dois descendentes.

Outra possibilidade de obtenção de novas soluções é o *crossover* uniforme, proposto por Syswerda (1989). A ideia é determinar uma porcentagem de genes que serão trocados entre os dois pais, a escolha desses genes é aleatória. Seguindo a ideia do *crossover* uniforme, Spears & DeJong (1991) propôs o *parametrized uniform crossover*, que difere do *crossover* uniforme por garantir que a probabilidade do filho herdar o alelo de um dos dois pais é de 50%, ou seja, a taxa de probabilidade de cada alelo herdado pelo filho é controlada.

Mutação

A mutação é um operador que realiza perturbações genéticas nos indivíduos com o objetivo de manter a diversidade na população. Ao introduzir essas perturbações

genéticas, novos indivíduos são criados na população, procurando proporcionar maior exploração do espaço de soluções. Normalmente, a taxa de indivíduos selecionados para participarem deste processo evolutivo é muito pequena, pois mutações excessivas podem alterar um número grande de boas soluções, que seriam perdidas no processo de mutação. Segundo Spears & DeJong (1991) a taxa de mutação deve ser inversamente proporcional ao tamanho da população.

Existem métodos alternativos de mutação, desenvolvidos para os diversos tipos de representação cromossômica (Bäck et al. 2000). Para a representação binária, uma mutação simples consiste em inverter o valor de cada gene com uma taxa de probabilidade pequena. Normalmente, essa taxa é de $1/A$, onde A é o tamanho do cromossomo. Na representação com valores reais, um ou mais genes podem ser escolhidos aleatoriamente e seus alelos podem ser modificados também aleatoriamente. Outra forma de mutação é a permutação entre dois, ou k , genes.

A mutação *insert* também é um método de permutação, porém é mais moderado, pois é escolhido aleatoriamente um gene do cromossomo e este é inserido em alguma outra posição do cromossomo. Da mesma forma, pode-se selecionar dois genes e trocar as posições dos dois no cromossomo – esta técnica é denominada mutação *swap*. A mutação *scramble* escolhe dois pontos aleatoriamente e os genes localizados entre esses dois pontos são permutados aleatoriamente (Bäck et al. 2000).

3.2 Características do BRKGA

O algoritmo genético baseado em chaves aleatórias *biased random-key genetic algorithm* (BRKGA) proposto por Gonçalves & Resende (2011a), é um representante do estado da arte na exploração do conceito de algoritmos genéticos (Eiben & Smith 2003). Tem sido aplicado em problemas difíceis de otimização combinatória, tais como problemas de roteamento (Buriol et al. 2005), empacotamento (Gonçalves & Resende 2011b) e *scheduling* (Mendes et al. 2009). Uma vez que Queiroz & Lyra (2009) foram bem sucedidos em utilizar uma formulação anterior do problema com algoritmos genéticos para resolver um problema semelhante ao estudado neste trabalho usando representações por chaves aleatórias, o BRKGA é uma escolha natural para abordar o problema de reconfiguração de redes.

O BRKGA é baseado no algoritmo genético de chaves aleatórias (do inglês, *Random-Key Genetic Algorithm* - RKGA) de Bean (1994). O RKGA e o BRKGA representa uma solução do problema com um vetor de n chaves, onde cada chave é um número real gerado aleatoriamente, no intervalo contínuo $[0, 1]$. O algoritmo geralmente começa com uma população inicial de p vetores com n chaves geradas aleatoriamente. De forma análoga a codificação de dois níveis adotada por Queiroz & Lyra (2009), as informações cromossômicas codificadas nos valores de chaves do BRKGA são decodificadas em fenótipos

para permitir a avaliação do *fitness* da solução.

A cada iteração, a população é dividida em duas subpopulações. A primeira subpopulação corresponde a um pequeno conjunto de p_e elementos que possuem os melhores valores de *fitness*, denominado *conjunto elite*; o restante da população compõe o *conjunto não-elite*. O conjunto elite é automaticamente copiado para a próxima geração. Em abordagens de algoritmos genéticos (Eiben & Smith 2003), os operadores de mutação são aplicados em alguns indivíduos da população, para reduzir a probabilidade de convergência para um ótimo local; com o mesmo objetivo, de reduzir a probabilidade de convergência para ótimos locais, o BRKGA produz um pequeno número de indivíduos gerados aleatoriamente (p_m indivíduos), denominados *mutantes*. Naturalmente, os *mutantes* fazem parte do *conjunto não-elite* (Gonçalves & Resende 2011a). A população da próxima geração é completada com $p - p_e - p_m$ vetores gerados via *crossover*.

O que difere o BRKGA ao RKGA é a seleção dos progenitores na realização do processo evolutivo *crossover*. No RKGA, os dois progenitores são escolhidos entre os indivíduos da população. No BRKGA, um progenitor é proveniente do conjunto elite e outro progenitor do conjunto não-elite. A Figura 3.3, baseada em Gonçalves & Resende (2011a), ilustra a transição da geração k para a geração $k + 1$ no processo evolutivo do BRKGA.

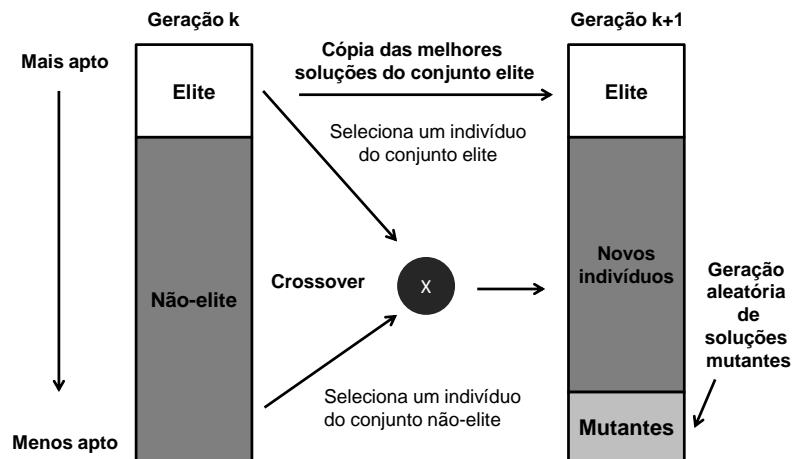


Figura 3.3: Transição da geração k para a geração $k + 1$ no BRKGA.

Resende e Ribeiro (Resende 2011) também propõem uma técnica que reinicializa o algoritmo BRKGA sempre que a melhor solução não mude no conjunto elite após k iterações; os autores testaram essa alternativa de reinicialização em uma instância do problema de recobrimento de Steiner (Resende et al. 2012). Vale observar que a estratégia de reinicialização, junto com o procedimento guloso (elitista), de transferir as melhores soluções de uma geração para a geração seguinte, são componentes bem-sucedidos da metaheurística GRASP que o BRKGA introduziu na estrutura dos algoritmos genéticos.

Os principais parâmetros que caracterizam uma implementação específico do BRKGA são o número de chaves de um cromossomo (n), o tamanho da população (p), o tamanho da população elite (p_e), o tamanho da população mutante (p_m) e a probabilidade do indivíduo gerado via *crossover* herdar o alelo do indivíduo que compõe o conjunto elite (ρ_e). Em Gonçalves & Resende (2011a), os autores realizam diversas experiências com os valores desses parâmetros no BRKGA, levando as recomendações apresentadas na Tabela 3.3.

Parâmetros	Descrição	Valor
p	tamanho da população	$p = an$, onde $1 \leq a \in \mathbb{R}$ é uma constante e n é o tamanho do cromossomo
p_e	tamanho da população elite	$0.10p \leq p_e \leq 0.25p$
p_m	tamanho da população mutante	$0.10p \leq p_m \leq 0.30p$
ρ_e	probabilidade de herança de alelos da elite	$0.5 < \rho_e \leq 0.8$

Tabela 3.3: Configurações de valores de parâmetros recomendados.

CAPÍTULO 4

SOLUÇÃO DO PROBLEMA POR ALGORITMO GENÉTICO BASEADO EM CHAVES ALEATÓRIAS (BRKGA)

“The things that I’ve loved, the things that I’ve lost
The things I’ve held sacred, that I’ve dropped
I won’t lie no more, you can bet
I don’t want to learn what I’ll need to forget.”

Audioslave - *Doesn’t Remind Me* (2005).

Este capítulo apresenta a estratégia de solução para o problema de reconfiguração de redes radiais com a presença de fontes distribuídas de valores de gerações aleatórios. A estratégia de solução é desenvolvida com a arquitetura de algoritmo genético baseado em chaves aleatórias (BRKGA), apresentada no capítulo anterior. O capítulo discute também uma estratégia de solução baseado em algoritmo genético híbrido, usada como referência de comparação para avaliar a capacidade de busca do BRKGA.

4.1 BRKGA para Redução de Perdas em Redes de Distribuição

Um esboço da estratégia para resolver o problema de reconfiguração de redes com o BRKGA é apresentado na Figura 4.1. Após os passos do pré-processamento para leitura dos dados da rede e definição dos parâmetros, o algoritmo gera uma população inicial de p indivíduos representados por n vetores de chaves aleatórias, com valores distribuídos uniformemente no intervalo $[0, 1]$. Em seguida, a informação cromossômica codificada nos valores de chaves do BRKGA dos p indivíduos da população é decodificada em fenótipos através do algoritmo de Kruskal, permitindo a avaliação do *fitness* – o processo de decodificação e avaliação é discutido nas próximas seções.

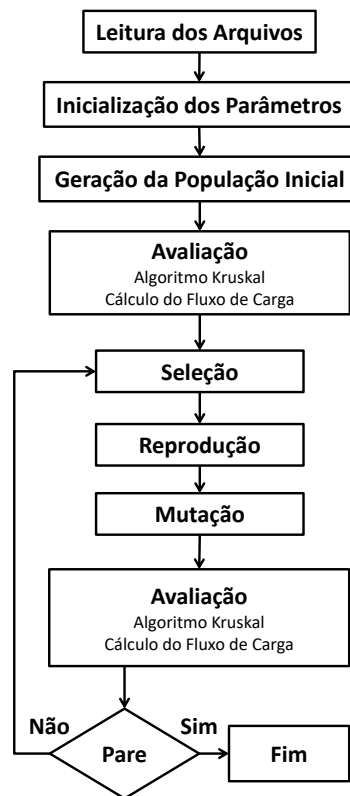


Figura 4.1: Fluxograma do BRKGA para o problema de reconfigura  o de redes.

A popula  o inicial   avaliada e separada em subpopula  es elite e n o-elite, que guiar o os processos evolutivos do BRKGA: sele  o, *crossover*, muta  o e novas avalia  es. O processo continua at  que n o sejam obtidas melhorias nas melhores solu  es, desencadeando um rein cio do algoritmo BRKGA ou fornecendo a melhor solu  o encontrada at  o momento, se o n mero m ximo de itera  es for atingido.

Pode-se observar que os passos representados na Figura 4.1 s o muito semelhantes ao procedimento de algoritmo gen tico padr o (Eiben & Smith 2003). Na verdade, a filosofia do BRKGA est  por tr s da cena, realizando os processos evolutivos. Nas pr ximas se  es ser o discutidos a representa  o cromoss mica, a avalia  o do *fitness*, o *crossover* e a estrat gia de muta  o, aspectos espec ficos importantes para a solu  o do problema de reconfigura  o de redes utilizando o BRKGA.

4.2 Representa  o do Cromossomo

Como mencionado anteriormente, os AGs s o utilizados com sucesso em muitos problemas de otimiza  o combinat ria. Entretanto, no problema de redu  o de perdas em redes de distribui  o, somente algumas aplica  es com AGs s o bem sucedidas devido   restri  o de radialidade da rede.

A representação do cromossomo é baseada na codificação *network random keys* (NRK) (Rothlauf et al. 2002), originalmente usada para o problema de reconfiguração de redes em da Costa (1999) e depois adotada por Vargas *et al.* (Vargas et al. 2004) e Queiroz & Lyra (2009). O NRK é uma representação baseada em arco, onde o número de chaves de um cromossomo (n) é igual ao número de arcos. Aqui, todas as chaves estão no intervalo contínuo $[0, 1]$ para melhor corresponder a filosofia do BRKGA – isto é análogo a codificação adotada por Queiroz (2005), na qual as chaves são números inteiros.

O algoritmo de Kruskal para obtenção de árvores de peso mínimo (Ahuja et al. 1993) é aplicado em cada indivíduo da população para obtenção da árvore associada ao cromossomo – isto é, o fenótipo. Em outras palavras, o algoritmo de Kruskal decodifica um vetor de n chaves, obtendo uma árvore. Esta representação de uma solução para o problema de reconfiguração de redes em dois níveis garante que o cromossomo de cada indivíduo da população está associada a uma configuração radial de rede. Por outro lado, a aplicação do algoritmo Kruskal para determinar a árvore de custo mínimo tem custo computacional baixo, em relação ao esforço total do processo de otimização para o problema de reconfiguração de redes (Queiroz & Lyra 2009).

A Figura 4.2 ilustra o processo de decodificação de uma rede radial a partir de um dado cromossomo. Na imagem, o cromossomo é associado a uma rede e o valor da chave associado a cada gene deste cromossomo representa o peso do arco – observa-se que os pesos associados aos arcos são os valores atribuídos aos genes durante o processo evolutivo (na população inicial, são valores aleatórios uniformemente distribuídos no intervalo $[0, 1]$). O algoritmo Kruskal determina a árvore de custo mínimo, ou seja, indica os arcos que participam da árvore associada ao cromossomo; implicitamente, indica as chaves que ficarão fechadas e as chaves que ficarão abertas na rede.

4.3 Função de Avaliação

A função de avaliação calcula o *fitness* de cada indivíduo, obtido a partir do valor da função objetivo dada pela Equação 2.2. O algoritmo utiliza um procedimento de duas etapas: a primeira etapa é a decodificação do cromossomo com o algoritmo Kruskal, que define os estados das chaves (os elementos do conjunto \mathcal{S}) e assegura o cumprimento da exigência de uma solução radial (Eq. 2.7); a segunda etapa é a computação dos fluxos de energia pela varredura *backward-forward* (Baran & Wu 1989), e a computação do valor da função objetivo associado ao indivíduo (Equação 2.2).

Após a definição da árvore (rede radial) correspondente ao cromossomo, o algoritmo faz uma numeração em preordem dos nós (e arcos) da árvore (Ahuja et al. 1993), como ilustra a Figura 4.3. A numeração é feita implicitamente, usando-se um conjunto de listas com os seguintes apontadores: apontador para o arco que liga ao antecessor do nó (arco pai), apontador para o nó antecessor (nó pai), apontador para o próximo nó da




Figura 4.2: Decodificação de uma rede radial de um cromossomo.

árvore quando percorrida em preordem (fio). Usa-se também uma lista com os níveis de profundidade dos nós da árvore.




Figura 4.3: Numeração em preordem de uma árvore representando uma rede radial.

A rede numerada em preordem é inicialmente percorrida em sentido inverso para determinação dos fluxos de potência definidos pelas Equações 2.5, partindo-se do nó folha numerado com o índice mais alto, até atingir a raiz. Em seguida, a rede é percorrida no sentido direto para cálculo das tensões definidos pelas Equações 2.6, partindo da raiz até o nó folha numerado com o índice mais alto.

Obtidas as informações de fluxos e tensões, calcula-se as perdas associadas à configuração, definida pelas Equações (2.2)-(2.4). Ou seja, calcula-se o *fitness* do indivíduo.

4.4 Crossover e Evolução

O *parametrized uniform crossover* proposto por Spears & DeJong (1991) é adotado no processo de reprodução (*crossover*) no BRKGA. Adotando-se esta forma de *crossover* na estratégia do BRKGA, dois cromossomos são selecionados aleatoriamente, um do *conjunto elite* e outro do *conjunto não-elite*. Um vetor de chaves aleatórias do mesmo tamanho dos cromossomos é gerado e utilizado como uma máscara na operação *crossover*. Se o valor da máscara for menor que ρ_a , a chave descendente correspondente herda o valor do pai do *conjunto elite*; caso contrário, ela herda o valor do pai do *conjunto não-elite*.

	a	b	c	d	e	f	g	h	i
Cromossomo elite	0,34	0,17	0,55	0,87	0,33	0,22	0,86	0,34	0,57
Cromossomo não-elite	0,28	0,19	0,91	0,45	0,28	0,27	0,88	0,21	0,95
Vetor de números aleatórios	0,60	0,91	0,68	0,27	0,60	0,93	0,68	0,27	0,83
Probabilidade de 0.7	<	>	<	<	<	>	<	<	>
Cromossomo descendente	0,34	0,19	0,55	0,87	0,33	0,27	0,86	0,34	0,95

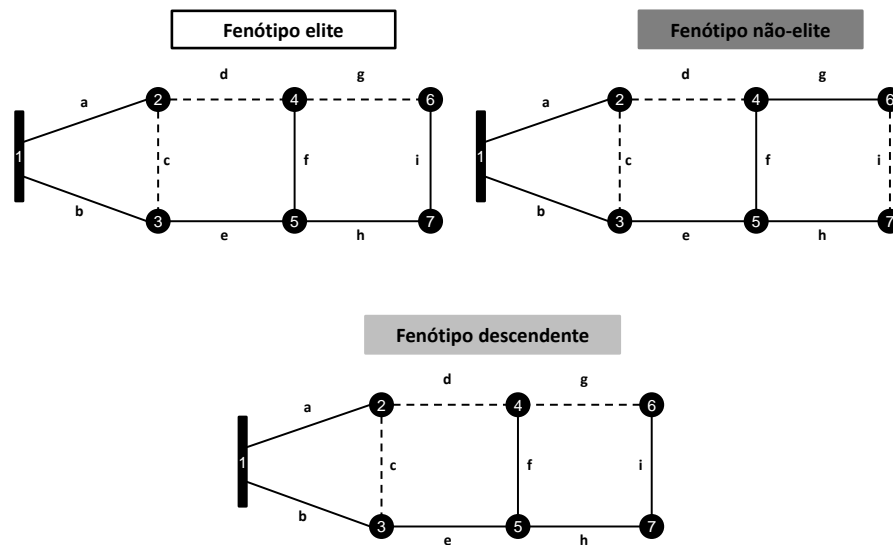


Figura 4.4: *crossover* uniforme parametrizado.

A Figura 4.4 ilustra o procedimento do *crossover* para dois vetores de chaves aleatórias. O primeiro vetor representa o cromossomo do pai elite e o segundo vetor é o cromossomo do pai não-elite. Como já foi mencionado anteriormente, o cromossomo é associado a uma rede radial por decodificação pelo algoritmo de Kruskal. Neste exemplo, o cromossomo possui 9 genes, ou seja, a rede possui 9 arcos. Os dois cromossomos são escolhidos aleatoriamente, sendo um do conjunto elite e outro do conjunto não-elite, para gerar um descendente que representa o quinto vetor na imagem. O terceiro vetor é formado

por chaves aleatórias, que permitem decidir se o gene de cada posição do novo indivíduo será do pai elite ou do pai não-elite.

A escolha é definida pelo valor do ρ_a , que, neste exemplo, possui valor de 0.7; o descendente vai herdar o alelo do pai elite com probabilidade de 0.7 e o alelo do pai não-elite com probabilidade de 0.3. O quarto vetor representa uma máscara do vetor de chaves aleatórias. Quando o valor da chave aleatória (do terceiro vetor) for menor ou igual a 0.7, o descendente vai herdar o alelo do pai elite; caso contrário, quando o valor da chave aleatória for maior que 0.7, o descendente herda o alelo do pai não-elite. No processo ilustrado na figura, foi herdado o alelo do pai não-elite nos genes representados com a cor cinza (ou seja, o valor da chave aleatória foi \geq a 0.7 nas posições **b**, **f** e **i**); o restante dos genes herdou o alelo do pai elite. Nota-se que o novo indivíduo “se parece” mais com o pai elite do que com o não-elite. Observa-se também que genótipos diferentes podem levar a um mesmo fenótipo.

4.5 Mutação

Como mencionado no capítulo anterior, o operador mutação possui um papel importante para os AGs. Seu objetivo é realizar modificações em alguns indivíduos selecionados aleatoriamente no problema. Durante o processo evolutivo, os indivíduos mais aptos são selecionados para participarem do processo de reprodução e passam seus códigos genéticos para as próximas gerações. Entretanto, se o algoritmo genético só seleciona os melhores e elimina os indivíduos menos aptos, o processo de solução tem maior probabilidade de restringir a busca a ótimos locais. A mutação procura criar condições para que o algoritmo genético escape desses ótimos locais.

Na implementação do BRKGA, o mutante é um vetor de chaves aleatórias gerado da mesma forma que um elemento da população inicial. A cada geração, um determinado número de mutantes (pm), é introduzido na população não-elite. Os indivíduos mutantes são gerados via *crossover*. O valor de p_m é um dos parâmetros pré-definidos para a implementação do algoritmo.

4.6 Algoritmo Genético Híbrido para a Solução do Problema de Reconfiguração de Redes

Nesta seção é apresentado um algoritmo genético híbrido para o problema de reconfiguração de redes com objetivo de avaliar comparativamente os benefícios da estratégia BRKGA. Adota-se uma representação determinística do problema, com o objetivo de reduzir o esforço computacional do processo de comparação.

4.6.1 Características Gerais do Algoritmos Genético Híbrido

O algoritmo genético híbrido é baseado na estratégia proposta por (Queiroz 2005). No seu desenvolvimento, foram adotadas as alternativas de implementação descritas a seguir.

- **Representação do cromossomo:** São vetores de chaves aleatórias, os mesmos utilizados para a implementação do BRKGA, apresentados na Seção 4.1;
- **População inicial:** p indivíduos representados por n vetores de chaves aleatórias, com valores distribuídos uniformemente no intervalo $[0, 1]$;
- **Operador seleção:** O método escolhido para a seleção dos indivíduos da população foi o torneio, explicado com detalhes na Subseção 3.1.4;
- **Operador *crossover*:** O método selecionado para a implementação do cruzamento foi o *crossover* uniforme, detalhado na Subseção 3.1.6;
- **Operador mutação:** O método escolhido para a implementação do AG híbrido foi o *scramble mutation*, detalhado na Subseção 3.1.6. No caso, 10% dos indivíduos da população são escolhidos para receber mutações;
- **Tamanho da população:** A população possui 100 indivíduos;
- **Função de avaliação:** A função de avaliação é o mesmo apresentado para o BRKGA, descrito com detalhes na Seção 4.3;
- **Critério de parada:** O critério de parada é o número máximo de gerações, para o qual foi considerado o valor 1000.

Para esta implementação adota-se uma representação determinística do problema de reconfiguração de redes, apresentada na próxima subseção.

4.6.2 Formulação Matemática do Problema Para o Caso Determinístico

A representação determinística do problema é apresentada pelas Equações 4.1-4.5, a seguir.

$$Min_{s_k \in S} \left[\sum_{k \in N} r_k \frac{(P_k)^2 + (Q_k)^2}{(v_k)^2} \right] \quad (4.1)$$

sujeito a

$$s_k \in \{0, 1\} \quad (4.2)$$

$$\forall k \in N \quad \begin{cases} P_k = \sum_{j \in A_k} P_{k,j} + P_{L_k} - P \cdot z_k \\ Q_k = \sum_{j \in A_k} Q_{k,j} + Q_{L_k} - Q \cdot z_k \end{cases} \quad (4.3)$$

$$\forall k \in N \quad \begin{cases} (v_{k+1,j})^2 = (v_k)^2 - \\ -2(r_{k+1,j}P_{k+1,j} + x_{k+1,j}Q_{k+1,j}) \end{cases} \quad (4.4)$$

$$G' = (N, A') \text{ é uma árvore} \quad (4.5)$$

onde s_k representa o estado da chave associado ao arco k (fechado se $s_k = 1$ e aberto se $s_k = 0$); N é o conjunto de nós da rede; r_k é a resistência da linha k , P_k , Q_k , e v_k são, respectivamente, a potência ativa e a potência reativa que flui no arco k , e o valor da tensão no nó k , quando a potência ativa P e a potência reativa Q são injetados pela fonte de geração; A_k é o conjunto de arcos com origem no nó k (emando do nó k); $P_{k,j}$ e $Q_{k,j}$ são, respectivamente, a potência ativa e reativa que flui nos arcos “ k, j ”, *sucessores* do nó k na *árvore* que representa o alimentador; P_{L_k} e Q_{L_k} são, respectivamente, cargas de potência ativa e reativa no nó k ; $z_k = 1$ se a fonte de geração estiver conectada ao nó k , e $z_k = 0$ caso contrário (observa-se que a formulação supõe a existência de apenas uma fonte de geração distribuída, com injeção significativa em relação ao total de cargas da rede); G' é um subgrafo que inclui todos os nós na rede e A' é o subconjunto do conjunto de arcos A que inclui todos os arcos com fluxos não-zero.

As Equações (4.3-4.4) são generalizações, por inclusão de geração distribuída, das equações simplificadas de DistFlow, estudadas em Baran & Wu (1989).

4.6.3 Busca Local

O que torna o AG híbrido é a inserção de buscas locais para melhorar a exploração do espaço de soluções. A busca local escolhida é baseada na heurística troca de ramos, proposto por Civanlar et al. (1988), generalizada para incluir gerações distribuídas de valores determinísticos. Esse tipo de busca local apresentou bons resultados no algoritmo genético híbrido para reconfiguração de redes radiais proposto por Queiroz & Lyra (2009).

A heurística realiza uma busca na vizinhança de uma solução, procurando por outra configuração que proporcione maior redução de perdas. Cada etapa da troca de ramos realiza troca entre um arco aberto e outro que esteja fechado em um mesmo ciclo. Civanlar et al. (1988) observaram que maiores reduções de perdas ocorrem quando as operações de troca de ramos são feitas com arcos que estejam do lado de menor tensão, entre as tensões nos nós terminais de uma chave aberta.

A implementação da busca local segue a estratégia de Baran & Wu (1989), que aperfeiçoaram o método de troca de ramos proposto por Civanlar et al., introduzindo

uma estimativa para redução de perdas entre o arco x (NA) e o arco y (NF). Identifica-se o arco correspondente a uma chave aberta e verifica-se qual nó deste arco possui menor valor de tensão. Em seguida, cria-se um conjunto, denominado A, com todos os arcos compreendidos entre o nó de menor tensão e o nó raiz do ciclo. Calcula-se a redução estimada de perdas entre arco x e o arco que está conectado com o nó de menor tensão do arco x . Se a redução de perdas for ≤ 0 , o método para e procura por outro arco aberto que ainda não tenha sido visitado. Se a redução de perdas for ≥ 0 , o método verifica o próximo arco do conjunto A até analisar todos seus arcos, ou até que a redução de perdas seja ≥ 0 .

Para registrar nos genótipos a operação de troca de arcos, alteram-se os genes dos arcos, atribuindo-se valores altos para os arcos que devem ser abertos e valores baixos para os arcos que devem ser fechados (Queiroz & Lyra 2009). A Figura 4.5 baseada em Queiroz & Lyra (2009) apresenta o fluxograma da heurística troca de ramos.

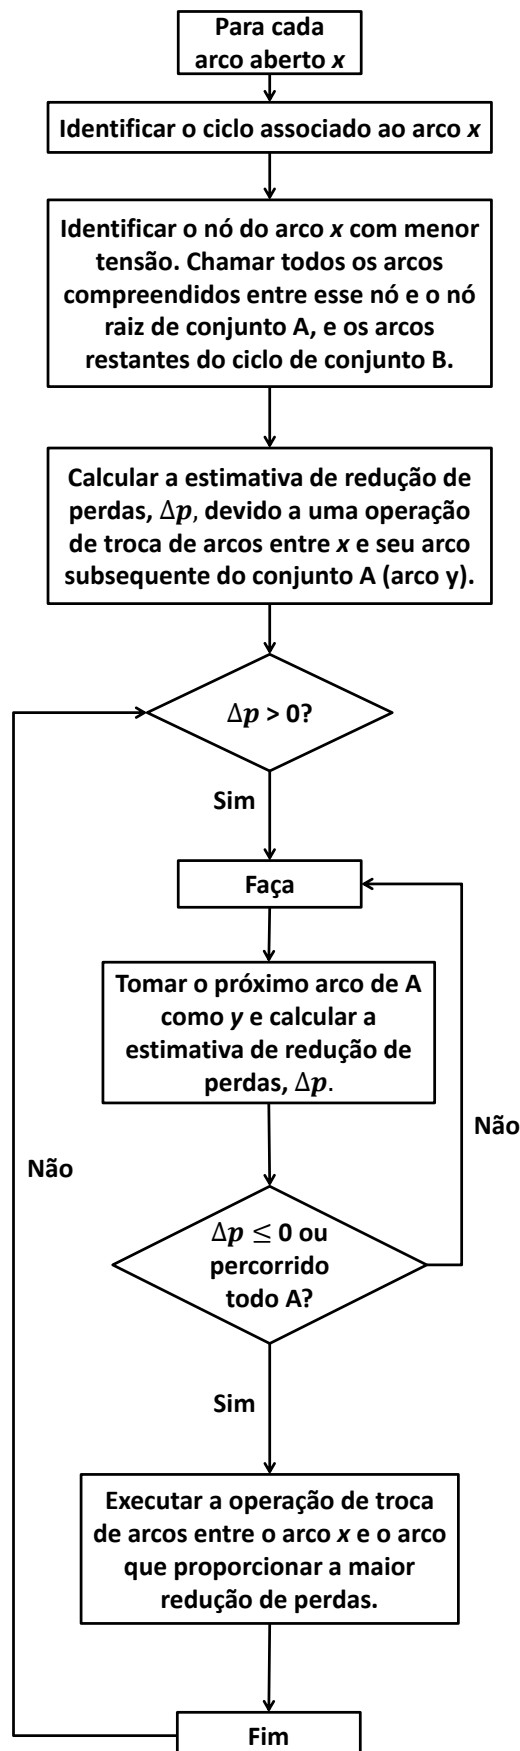


Figura 4.5: Método de troca de ramos.

CAPÍTULO 5

ESTUDO DE CASOS

“Oh, let the sun beat down upon my face
Stars to fill my dream
I am a traveler of both time and space
To be where I have been.”

Led Zeppelin - *Kashmir* (1975).

Este capítulo, apresenta estudos de casos para avaliação da metodologia proposta para o problema de reconfiguração de redes com gerações distribuídas de valores aleatórios. A próxima seção descreve as características das redes usadas nos estudos de casos. A Seção 5.2 apresenta o ambiente computacional e os parâmetros adotados no BRKGA. A Seção 5.3 descreve as comparações do BRKGA com algoritmo genético híbrido no problema determinístico apresentado no capítulo anterior. Avaliações adicionais do BRKGA são apresentadas na Seção 5.4. A Seção 5.5 descreve os estudos de caso sobre obtenção de configurações ótimas para redes com gerações distribuídas de valores aleatórios.

5.1 Características das Redes

A metodologia foi avaliada em seis redes radiais propostas na literatura. A Tabela 5.1 resume os principais dados para essas redes¹. A rede 1 foi proposta por Civanlar *et al.* (Civanlar et al. 1988), a rede 2 foi originalmente utilizado por Baran e Wu (Baran & Wu 1989), a rede 3 foi adotada por Su *et al.* (Su et al. 2005), a rede 4 e a rede 5 foram utilizados por Guimarães e Castro (Guimarães & Castro 2005), e a rede 6 foi adotado por Abadei and Kavasseri (Ababei & Kavasseri 2011). Os dados na Tabela 5.1 também incluem um nó raiz adicional, conectado a cada uma das subestações

¹ dados estão disponíveis em <http://www.dejazzer.com/reds.html>

– esses nós podem ser interpretados como representações condensadas das conexões com a rede de transmissão. Um esboço da topologia de cada uma dessas redes é apresentado no Apêndice A.

Rede	Nós	Arcos	Alimentadores	Chaves abertas	Chaves fechadas	Cargas Totais	
						P (kW)	Q (kVAr)
rede 1	17	19	3	3	16	28700	5900
rede 2	34	38	1	5	33	3715	2300
rede 3	95	107	11	13	94	28350	20700
rede 4	144	164	8	21	143	18312	7930
rede 5	205	219	3	15	204	27571	17084
rede 6	881	907	7	27	880	124871	74362

Tabela 5.1: Dados das redes.

5.2 Recursos Computacionais e Parâmetros do BRKGA

5.2.1 Recursos Computacionais

Todos os algoritmos foram codificados em MATLAB e as simulações foram realizadas em um PC com Intel Core i7-4790 CPU executando em 3.60GHz, 16Gb RAM e sistema operacional Windows 64 bits.

5.2.2 Parâmetros do BRKGA

A Tabela 5.2 resume os parâmetros do BRKGA, que foram baseados nos valores recomendados por Gonçalves & Resende (2011a).

Parâmetros	Descrição	Valor
p	tamanho da população	100
p_e	tamanho da população elite	20
p_m	tamanho da população mutante	10
ρ_a	probabilidade de herança de alelos da elite	0.7

Tabela 5.2: Parâmetros adotados no BRKGA.

A reinicialização do BRKGA foi aplicada quando o melhor indivíduo do conjunto elite não obteve melhoras na solução após 50 (iterações) gerações. Caso contrário, o processo de otimização finaliza após 1000 gerações.

5.3 Comparação do BRKGA com o AG Híbrido

Os benefícios da estratégia BRKGA foram inicialmente avaliados na solução do problema de reconfigurações de redes com fontes distribuídas de valores determinísticos, descrito na Seção 4.6.2. Três alternativas para solução do problema de reconfiguração de

redes foram implementadas: *BRKGA 1*, algoritmo genético baseado em chaves aleatórias com busca local; *BRKGA 2* algoritmo genético baseado em chaves aleatórias sem busca local; *AG 1* algoritmo genético com busca local. O *BRKGA 1* foi desenvolvido para verificar se a arquitetura BRKGA poderia ser beneficiada com a introdução de buscas locais. Adotou-se como valor das injeções determinísticas a média dos valores de injeções apresentados na Tabela 5.6. A Tabela 5.3 apresenta o valor para perdas em kW e os tempos computacionais em segundos para o *BRKGA 1*, *BRKGA 2* e *AG 1*.

Rede	Valor Estimado para Perdas (kW)			Tempo Computacional (segundos)		
	BRKGA 1	BRKGA 2	AG 1	BRKGA 1	BRKGA 2	AG 1
rede 1	278,6	278,6	278,6	45,9	48,0	51,3
rede 2	116,9	116,9	116,9	77,1	71,3	82,8
rede 3	477,0	476,8	490,9	291,9	157,3	294,7
rede 4	238,6	241,1	268,0	690,4	245,1	737,6
rede 5	456,2	447,6	545,3	863,3	276,8	867,7
rede 6a	446,0	467,0	599,0	17240,9	1013,5	17248,6
rede 6b	454,7	444,2	643,5	15874,3	1009,5	16865,8
rede 6c	466,3	460,1	711,9	15666,3	1034,3	16758,1
rede 6d	521,6	525,2	654,1	19870,3	1003,2	16558,0

Tabela 5.3: Perdas e tempos de processamento.

Os resultados apresentados na Tabela 5.3 permitem as seguintes observações:

- Os estudos de casos mostraram que a introdução de busca local no BRKGA não levou a uma melhoria consistente na qualidade das soluções;
- Os tempos computacionais para obtenção de soluções com o BRKGA foram sempre substancialmente menores do que os tempos exigidos pelo AG híbrido;
- O BRKGA sem busca local apresentou melhores resultados do que o AG híbrido, tornando o BRKGA mais atraente que o AG para a solução do problema de reconfiguração de redes com injeções aleatórias.

Considerando esses resultados, todos os testes e estudos de casos discutidos nos próximos itens serão realizados com o *BRKGA 2*, que será denominado simplesmente BRKGA.

5.4 Testes Adicionais

Testes adicionais foram realizados para analisar os parâmetros do BRKGA. O parâmetro probabilidade de herança de alelos do pai elite (ρ_a) foi testado para os valores 0.5, 0.6, 0.7, 0.8 e 0.9. O valor 0.7 foi o que apresentou melhores resultados, como é recomendado em Gonçalves & Resende (2011a) e Roque et al. (2014). A Tabela 5.4 apresenta o valor estimado para as perdas em kW para os diferentes valores de ρ_a .

Outro teste adicional analisou a reinicialização do algoritmo quando o melhor indivíduo do conjunto elite não proporcione uma solução com redução de perdas após 25,

ρ_a	Valor Estimado para Perdas (kW)					
	rede 1	rede 2	rede 3	rede 4	rede 5	rede 6a
0.5	297,8	117,2	493,7	257,3	434,8	451,4
0.6	297,8	117,2	493,7	256,8	466,1	462,8
0.7	297,8	117,2	493,7	253,1	430,2	447,8
0.8	297,8	117,2	493,7	260,6	479,4	458,1
0.9	297,8	117,2	494,0	259,1	458,5	460,6

Tabela 5.4: Valores de ρ_a testados para as redes 1, 2, 3, 4, 5 e 6a.

50, 200 e 250 iterações (gerações). Os melhores resultados foram obtidos quando a reinicialização foi feita após 50 iterações; portanto, este valor foi utilizado na implementação da reinicialização do BRKGA.

Rede	Valor Estimado para Perdas (kW)				Tempo Computacional (segundos)			
	Reinicialização				Reinicialização			
	25	50	200	250	25	50	200	250
rede 1	297,8	297,8	297,8	297,8	66,5	47,6	65,1	70,3
rede 2	117,2	117,2	117,2	117,2	87,0	73,1	91,3	99,7
rede 3	493,9	493,7	493,7	493,7	266,0	165,5	255,3	270,9
rede 4	255,9	253,1	255,9	259,0	368,7	248,2	350,8	376,9
rede 5	437,1	430,2	458,5	490,2	402,1	307,9	412,3	450,2
rede 6a	464,5	447,8	450,2	452,1	1484,4	1060,6	1528,1	1565,6
rede 6b	453,4	445,2	448,9	455,5	1501,5	1109,2	1543,3	1542,3
rede 6c	459,5	456,2	468,7	462,3	1515,0	1088,2	1533,9	1555,8
rede 6d	536,8	528,7	531,2	551,1	1488,1	1116,9	1565,4	1555,4

Tabela 5.5: Perdas e tempos de processamento para reinicialização com valores de 25, 50, 200 e 250.

5.5 Avaliação do BRKGA para o Problema de Reconfiguração de Redes com Fontes Distribuídas de Valores Aleatórios

Uma única fonte de energia aleatória com três valores de injeções possíveis foi considerada em todos os estudos de caso. A Tabela 5.6, mostra para cada rede, o nó ao qual a fonte foi conectada, os possíveis valores de potência ativa e as respectivas probabilidades. Injeções de potência reativa foram supostas nulas. Para explorar a rede 6 foram consideradas quatro valores de potência ativa, caracterizando, respectivamente, as redes 6a, 6b, 6c e 6d.

A Tabela 5.7 fornece o valor esperado para as perdas e os tempos de processamento para *Alternativa 1*, *Alternativa 2* e *Alternativa 3*. A *Alternativa 1* representa a fonte de geração de valor aleatório por um valor determinístico, correspondente ao valor médio esperado das injeções; ou seja, resolve o problema estudado na seção anterior. A *Alternativa 2* adota a configuração obtida com a *Alternativa 1*, mas calcula o valor esperado das

Rede	Nó	Geração Valor 1		Geração Valor 2		Geração Valor 3	
		Prob.	Potência (kW)	Prob.	Potência (kW)	Prob.	Potência (kW)
rede 1	4	0.2	10000	0.5	15000	0.3	20000
rede 2	4	0.2	568	0.5	852	0.3	1136
rede 3	62	0.2	5680	0.5	8520	0.3	11360
rede 4	62	0.2	5680	0.5	8520	0.3	11360
rede 5	62	0.2	5680	0.5	8520	0.3	11360
rede 6a	15	0.2	5068	0.5	7602	0.3	10136
rede 6b	15	0.2	8000	0.5	12000	0.3	16000
rede 6c	15	0.2	15000	0.5	22000	0.3	30000
rede 6d	15	0.2	30000	0.5	45000	0.3	60000

Tabela 5.6: Valores de injeções aleatórias.

perdas, usando a função objetivo para o problema caracterizado pelas Equações (2.2)-(2.4). A *Alternativa 3* corresponde a melhor solução encontrada pelo BRKGA para o problema com fontes distribuídas aleatórias definido pelas Equações (2.2)-(2.7). Como discutido no Capítulo 2 (problema maquete), as perdas obtidas para *Alternativa 1* devem ser menores ou iguais às perdas obtidas para *Alternativa 2* e *Alternativa 3*. As perdas obtidas na *Alternativa 3* devem ser menores ou iguais às perdas obtidas para a *Alternativa 2*.

Rede	Valor Estimado para Perdas (kW)			Tempo Computacional (segundos)		
	Alternativa 1	Alternativa 2	Alternativa 3	Alternativa 1	Alternativa 2	Alternativa 3
rede 1	278,6628	297,8995	297,8995	47,6875	47,6875	64,5469
rede 2	116,9112	117,2608	117,2608	73,1406	73,1406	88,0938
rede 3	477,0572	494,0197	493,7928	165,5156	165,5156	247,625
rede 4	243,9757	263,8642	253,1650	248,2188	248,2188	388,0781
rede 5	427,3726	430,7554	430,2767	307,0938	307,0938	449,1406
rede 6a	447,4062	447,7178	447,8747	1060,6250	1060,6250	1535,3281
rede 6b	445,2575	446,0324	445,2128	1109,2188	1109,2188	1488,7656
rede 6c	454,3479	457,4574	456,2179	1088,2969	1088,2969	1487,0000
rede 6d	521,6853	533,8055	528,7824	1116,9688	1116,9688	1526,4063

Tabela 5.7: Perdas e tempos de processamento.

Os resultados apresentados na Tabela 5.7 permitem as seguintes observações.

1. A diferença nos valores de perdas entre *Alternativa 2* e *Alternativa 3* aumentam à medida que o tamanho da rede aumenta, indicando que o modelo mais rico é mais significativo à medida que aumenta o tamanho da rede e o espaço de possíveis configurações.
2. Todos os tempos computacionais da *Alternativa 3* foram inferiores ao dobro dos tempos computacionais da *Alternativa 2*; portanto, o modelo mais rico para o problema de reconfiguração de redes não levou a um aumento excessivo nos custos computacionais. Este resultado poderia ser esperado, porque a complexidade computacional do problema resulta principalmente do tamanho do espaço de soluções (o número de árvores factíveis); consequentemente, o maior número de variáveis

resultantes da inclusão de algumas fontes aleatórias adicionais também não deve conduzir a problemas intratáveis.

3. A estratégia de solução baseada no algoritmo BRKGA é uma abordagem adequada para tratar o problema de reconfiguração de redes definido pelas Equações (2.2)-(2.7).
4. Observou-se que o aumento dos valores de energia injetada pela fonte de valores aleatórios pode levar a um aumento nas perdas (casos 6c e 6d). De fato, valores altos de injeções podem substituir quase todo o fluxo injetado nas subestações, aumentando significativamente os fluxos em linhas de resistências altas; no entanto, como já mencionado no Capítulo 2, esta situação tem pouca aderência à realidade; indicam apenas que os alimentadores precisariam ser reprojitados para se adequarem ao novo cenário.

CAPÍTULO 6

CONCLUSÕES E PERSPECTIVAS DE TRABALHOS FUTUROS

“How I wish
How I wish you were here
We’re just two lost souls
Swimming in a fish bowl
Year after year
Running over the same old ground
What have we found?
The same old fears
Wish you were here.”

Pink Floyd - *Wish You Were Here* (1975).

Um aspecto chave para o problema de reconfiguração de redes após a virada do século é o surgimento de geração distribuída, que inclui fontes de energia renováveis com injeções aleatórias. A análise dos efeitos destas fontes de energia com valores aleatórios sobre o problema de reconfiguração de redes, a proposição de um modelo matemático que leva essas fontes em consideração, o desenvolvimento de uma estratégia de solução e a avaliação da metodologia sobre problemas de referência foram os objetos desta dissertação.

Inicialmente, o trabalho caracterizou uma função objetivo que expressou o valor esperado para as perdas. Esta nova perspectiva para o problema de reconfiguração de redes foi investigada em uma rede maquete, que permitiu captar novos aspectos importantes a serem incorporados no modelo matemático. As inovações resultaram em um aumento no tamanho do problema de otimização e, conseqüentemente, aumentaram a dificuldade de encontrar soluções ótimas. O desenvolvimento de uma estratégia de otimização baseada no algoritmo genético baseado em chaves aleatórias (BRKGA) foi uma contribuição complementar do trabalho.

Estudos de casos com redes de referência submeteram a metodologia proposta a testes de campo e colocaram em perspectiva os benefícios de considerar formalmente

os valores esperados para as perdas, quando fontes de injeções aleatórias de energia estão conectadas às redes de distribuição. Os benefícios são observáveis quando os valores e as variâncias das fontes aleatórias são significativas, quando comparados com as cargas nas redes. Além disso, a necessidade de considerar a metodologia proposta é enfatizada quando o tamanho da rede e o número de possíveis configurações aumentam.

O efeito das cargas aleatórias, como demandas de estações de recargas para veículos elétricos, pode ser abordado de forma similar com a metodologia proposta. Uma questão que permanece aberta é como encontrar as configurações ótimas de redes quando um grande número de pequenas fontes intermitentes injeta energia nas redes. Um possível ponto de partida para lidar com esta questão é acoplar a metodologia proposta aqui com técnicas de agregação.

REFERÊNCIAS BIBLIOGRÁFICAS

- Ababei, C. & Kavasseri, R. (2011), ‘Efficient network reconfiguration using minimum cost maximum flow based branch exchanges and random walks based loss estimations’, *IEEE Transactions on Power Systems* **26**(1), 30–37.
- Ahuja, R., Magnanti, T. & Orlin, J. (1993), *Network Flows: Theory, Algorithms and Application*, Prentice Hall, Englewood Cliffs.
- Aoki, K., Ichimori, T. & Kanezashi, M. (1987), ‘Normal state optimal load allocation in distribution systems’, *IEEE Transactions on Power Delivery* **2**(1), 147–155.
- Bäck, T., Fogel, D. & Michalewicz, Z., eds (2000), *Evolutionary Computation 1: Basic Algorithms and Operators*, Institute of Physics Publishing, Bristol.
- Baran, M. E. & Wu, F. F. (1989), ‘Network reconfiguration in distribution systems for loss reduction and load balancing’, *IEEE Transactions on Power Delivery* **4**(2), 1401–1407.
- Bean, J. C. (1994), ‘Genetic algorithms and random keys for sequencing and combinatorial and optimization’, *Journal on Computing* **6**(2), 154–180.
- Bernardon, D. P., Garcia, V. J., Pfitscher, L. L., Sperandio, M., Canha, L. N. & Ramos, M. (2012), Smart grid concepts applied to distribution network reconfiguration, 2012 47th International Universities Power Engineering Conference (UPEC), London, pp. 1–6.
- Bernardon, D. P., Mello, A. P. C. & Pfischer, L. L. (2016), Real-time reconfiguration of distribution network with distributed generation, in ‘Real-time Systems’, InTech.
- Bernardon, D. P., Mello, A. P. C., Pfischer, L. L., Canha, L. N., Abaide, A. R. & Ferreira, A. A. B. (2014), ‘Real-time reconfiguration of distribution network with distributed generation’, *Electric Power Systems Research* **107**, 59–67.

- Bueno, E. A. (2000), Redução de perdas na distribuição de energia elétrica pelo método grasp, Mestrado, FEEC - Universidade Estadual de Campinas, Campinas - SP - Brasil.
- Bueno, E. A., Lyra, C. & Cavellucci, C. (2004), 'Distribution network reconfiguration for loss reduction with variable demands', *Transmission and Distribution Conference and Exposition: Latin America, 2004 IEEE/PES* pp. 384–389.
- Buriol, L. S., Resende, M. G. C., Ribeiro, C. C. & Thorup, M. (2005), 'A hybrid genetic algorithm for the weight setting problem in ospf/is-is routing', *Networks* **46**(1), 36–56.
- Cavalheiro, E. M. B., Vergílio, A. H. B. & Lyra, C. (2016), Configurações Ótimas de redes de distribuição de energia elétrica com gerações distribuídas de valores aleatórios, in 'Anais do XLVIII SBPO', 2016 XLVIII Simpósio Brasileiro de Pesquisa Operacional - SBPO, Vitória, ES, pp. 1–9.
- Cavellucci, C. (1998), Buscas informadas baseadas em grafos para minimização das perdas em sistemas de distribuição de energia elétrica, Phd, Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas - UNICAMP, Campinas - SP, Brasil.
- Cavellucci, C. & Lyra, C. (1997), 'Minimization of energy losses in electric power distribution systems by intelligent search strategies', *International Transactions in Operational Research* **4**(1), 23–33.
- Civanlar, S., Grainger, J. J., Yin, H. & Lee, S. S. H. (1988), 'Distribution feeder for loss reduction', *IEEE Transactions on Power Delivery* **3**(3), 1217–1223.
- da Costa, M. F. N. (1999), Evolutionary computation for resistive loss minimization on electric power distribution systems (in portuguese), Master, Shool of Electrical and Computer Engineering, University of Campinas - UNICAMP, Campinas - SP, Brazil.
- Darwin, C. (1859), *On the Origin of Species by Means of Natural Selection, or the Preservation of Favoured Races in the Struggle for Life*, John Murray, Londres.
- Das, S., Das, D. & Patra, A. (2016), Distribution network reconfiguration using distributed generation unit considering variations of load, 2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES).
- De Jong, K. A. (1975), An Analysis of the Behavior of a Class of Genetic Adaptive Systems., PhD thesis, Ann Arbor, MI, USA. AAI7609381.
- Eiben, A. E. & Smith, J. E. (2003), *Introduction to Evolutionary Computing*, Springer-Verlag, Berlin, Germany.

- Esmaeilian, H. R. & Fadaeinedjad, R. (2015), ‘Energy loss minimization in distribution systems utilizing an enhanced reconfiguration method integrating distributed generation’, *IEEE Systems Journal* **9**(4), 1430–1439.
- Fogel, D. B. (1995), *Evolutionary Computation: Toward a New Philosophy of Machine Intelligence*, IEEE Press, Piscataway, NJ, USA.
- Franco, J. F., Rider, M. J., Lavorato, M. & Romero, R. (2013), ‘A mixed-integer lp model for the reconfiguration of radial electric distribution systems considering distributed generation’, *Electric Power Systems Research* **97**, 51–60.
- Goldberg, D. E. (1989), *Genetic Algorithms in Search Optimization and Machine Learning*, Addison Wesley, Massachusetts.
- Gonçalves, J. F. & Resende, M. G. C. (2011a), ‘Biased random-key genetic algorithms for combinatorial optimization’, *Journal of Heuristics* **17**(5), 487–525.
- Gonçalves, J. F. & Resende, M. G. C. (2011b), ‘A parallel multi-population genetic algorithm for a constrained two-dimensional orthogonal packing problem’, *Journal of Combinatorial Optimization* **22**(2), 180–201.
- Guimarães, M. A. N. & Castro, C. A. (2005), Reconfiguration of distribution systems for loss reduction using tabu search, 15th Power System Computation Conference (PSCC), Liège, pp. 1–6.
- Holland, J. H. (1975), *Adaptation in Natural and Artificial Systems*, The University of Michigan Press, Ann Arbor, MI.
- IEEE PES Smart Grids (2016), <https://twitter.com/search?q=The%2023SmartGrid%20ppportunity%20-%20%40solarcity%27s%20interpretation%20of%20the%20smart%20grid&src=typd>. Accessed: 2016-06-08.
- Jagtap, K. M. & Khatod, D. K. (2016), ‘Loss allocation in radial distribution networks with various distributed generation and load models’, *Electrical Power and Energy Systems* **75**, 173–186.
- Kagan, N., Oliveira, C. C. B. & Robba, E. J. (2005), *Introdução aos Sistemas de Distribuição de Energia Elétrica*, Edgard Blücher.
- Lee, R. E. & Brooks, L. C. (1988), ‘A method and its application to evaluate automated distribution control’, *IEEE Transactions on Power Delivery* **3**(3), 1232–1240.
- Lightner, E. M. & Widergren, S. E. (2010), ‘An orderly transition to a transformed electricity system’, *IEEE Transactions on Smart Grid* **1**(1), 3–10.

- Liu, C. C., Lee, S. J. & Vu, K. (1989), ‘Loss minimization of distribution feeders: Optimality and algorithms’, *IEEE Transactions on Power Delivery* **4**(2), 1281–1289.
- McDermott, T. E., Drezga, I. & Broadwater, R. P. (1999), ‘A heuristic nonlinear constructive method for distribution system reconfiguration’, *IEEE Transactions on Power Systems* **14**(2), 478–483.
- Mendes, J. J. M., Gonçalves, J. F. & Resende, M. G. C. (2009), ‘A random key based genetic algorithm for the resource constrained project scheduling problem’, *Computers & Operations Research* **36**(1), 92–109.
- Merlin, A. & Back, H. (1975), ‘Search for a minimal-loss operating spanning tree configuration in an urban power distribution system’, *Proc. 5th Power System Computation Conference* pp. 1–18.
- Nara, K., Shiose, A., Kitagawa, M. & Ishihara, T. (1992), ‘Implementation of genetic algorithm for distribution systems loss minimum re-configuration’, *IEEE Transactions on Power Systems* **7**(3), 1044–1051.
- Ochoa, L. F. & Harrison, G. P. (2011), ‘Minimizing energy losses: Optimal accommodation and smart operation of renewable distributed generation’, *IEEE Transactions on Power Systems* **26**(1), 198–205.
- Oliveira, F. J. A. d. (2014), Fontes alternativas de energia: Energia elétrica e energia solar, in ‘Anais do Seminário Técnico Sobre Usinas Hidrelétricas Reversíveis’, Eletrobrás, Brasília.
- Possemato, F., Paschero, M., Livi, L., Rizzi, A. & Sadeghian, A. (2016), ‘On the impact of topological properties of smart grids in power losses optimization problems’, *International Journal of Electrical Power & Energy Systems* **78**, 755–764.
- Queiroz, L. M. O. (2005), Hybrid genetic algorithms for loss reduction in primary distribution networks considering demand variations (in portuguese), Master, School of Electrical and Computer Engineering, University of Campinas - UNICAMP, Campinas - SP, Brazil.
- Queiroz, L. M. O. & Lyra, C. (2009), ‘Adaptive hybrid genetic algorithm for technical loss reduction in distribution networks under variable demands’, *IEEE Transactions on Power Systems* **24**(1), 445–453.
- Ramaswamy, P. C. & Deconinck, G. (2012), Smart grid reconfiguration using simple genetic algorithm and nsga-ii, 2012 3rd IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe), Berlin, pp. 1–8.

- Rao, R. S., Ravindra, K., Satish, K. & Narasimham, S. V. L. (2013), ‘Power loss minimization in distribution system using network reconfiguration in the presence of distributed generation’, *IEEE Transactions on Power Systems* **28**(1), 317–325.
- Resende, M. G. C. and Ribeiro, C. C. (2011), ‘Restart strategies for grasp with path-relinking heuristics’, *Optimization Letters* **5**(3), 467–478.
- Resende, M. G. C., Toso, R. F., Gonçalves, J. F. & Silva, R. M. A. (2012), ‘A biased random-key genetic algorithm for the steiner triple covering problem’, *Optimization Letters* **6**(4), 605–619.
- Roque, L. A. C., Fontes, D. B. M. M. & Fontes, F. A. C. C. (2014), ‘A hybrid biased random key genetic algorithm approach for the unit commitment problem’, *Journal of Combinatorial Optimization* **28**(1), 140–166.
- Rosseti, G. J. S., Oliveira, E. J. d., Oliveira, L. W. d., Silva Jr., I. C. & Peres, W. (2013), ‘Optimal allocation of distributed generation with reconfiguration in electric distribution systems’, *Electric Power Systems Research* **103**, 178–183.
- Rothlauf, F., Goldberg, D. & Heinzl, A. (2002), ‘Network random keys: a tree representation scheme for genetic and evolutionary algorithms’, *Evolutionary Computation* **10**(1), 75–97. doi: 10.1162/106365602317301781.
- Shirmohammadi, D. & Hong, H. W. (1989), ‘Reconfiguration of electric distribution networks for resistive line losses reduction’, *IEEE Transactions on Power Delivery* **4**(2), 1492–1498.
- Spears, W. M. & DeJong, K. A. (1991), On the virtues of parameterized uniform crossover, In Proceedings of the Fourth International Conference on Genetic Algorithms, pp. 230–236.
- Su, C. T., Changb, C. F. & Chiouc, J. P. (2005), ‘Distribution network reconfiguration for loss reduction by ant colony search algorithm’, *Electric Power Systems Research* **75**(2-3), 190–199.
- Syswerda, G. (1989), Uniform crossover in genetic algorithms, in ‘Proceedings of the 3rd International Conference on Genetic Algorithms’, Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, pp. 2–9.
- Tahboub, A. M., Pandi, V. R. & Zeineldin, H. H. (2015), ‘Distribution system reconfiguration for annual energy loss reduction considering variable distributed generation profiles’, *IEEE Transactions on Power Delivery* **30**(4), 1677–1685.

- Taylor, T. & Lubkeman, D. (1990), ‘Implementation of heuristic search strategies for distribution feeder reconfiguration’, *IEEE Transactions on Power Delivery* **5**(1), 239–246.
- Vargas, P. A., Lyra, C. & Von Zuben, F. J. (2004), ‘Application of learning classifier systems to the on-line reconfiguration of electric power distribution networks’, *Studies in Fuzziness and Soft Computing* **150**, 260–275.
- Wu, Y. K., Lee, C. Y., Liu, L. C. & Tsai, S. H. (2010), ‘Study of reconfiguration for the distribution system with distributed generators’, *IEEE Transactions on Power Delivery* **25**(3), 1678–1685.
- Zhu, J. Z. (2002), ‘Optimal reconfiguration of electrical distribution network using the refined genetic algorithm’, *Electric Power Systems Research* **62**(1), 37–42.

[illegible]

Figura A.1: Rede 1




Figura A.2: Rede 2




Figura A.3: Rede 3




Figura A.4: Rede 4



Figura A.5: Rede 5




Figura A.6: Rede 6